

## ارایه یک شبکه عصبی ترکیبی برای حل مسأله فروشنده دوره‌گرد(TSP)

مهدی سعادتمند، محمد رضا اکبرزاده توتونچی، مرتضی خادمی

دانشکده مهندسی دانشگاه فردوسی مشهد، ایران

P.O. Box: 91775-1111, Mashhad, Iran

m\_saadatmand\_tarzjan@hotmail.com

### کلید واژه‌ها

شبکه‌های عصبی رقابتی، شبکه عصبی کوهونن، Traveling Salesman Problem (TSP)، شبکه عصبی هاپفیلد.

### خلاصه

شبکه عصبی هاپفیلد به خاطر ساختار ساده و فیدبکی‌اش، در حل مسایل بهینه‌سازی از جمله TSP مورد توجه است. از طرفی شبکه عصبی کوهونن به دلیل شیوه آموزش رقابتی و خصوصیات مکانشناصی‌اش (topological)، ابزاری مناسب برای حل این مسأله می‌باشد. هر کدام از این دو شبکه در کنار مزیتها یا شان دارای معایبی نیز هستند. پاسخهای هاپفیلد به علت حضور مینیمم‌های محلی در تابع انرژی‌اش چندان قابل قبول نیست. سرعت کوهونن نیز در پاسخ به این مسأله کم است و از آن نمی‌توان برای کاربردهای بلادرنگ استفاده کرد. در این مقاله یک شبکه فیدبکی-رقابتی ارائه شده است که مانند کوهونن پاسخهای قابل قبولی به TSP می‌دهد و مانند هاپفیلد سریع است. شبیه‌سازی‌های انجام شده دقت و سرعت شبکه را برای TSP‌های ۳۰ شهری در مقایسه با شبکه عصبی کوهونن و برای TSP‌های ۱۰۰ شهری در مقایسه با چند آلگوریتم دیگر نشان می‌دهد. همچنین پاسخ شبکه به یک TSP می‌تواند به ۲۸۰ شهری نیز ارائه شده است.

### ۱- مقدمه

مسایل بهینه‌سازی ترکیبی، از قبیل مسأله فروشنده دوره‌گرد (TSP) از خانواده مسایل NP-Complete هستند [2]. با پیشرفت تکنولوژی، نیاز به حل سریعتر و مناسب‌تر این مسایل افزایش یافته است. تعیین مسیر حرکت مته برای سوراخ‌کردن صفحه‌های PCB [7]، تعیین مسیر بهینه انتقال داده در شبکه‌های کامپیوتري [3]، پردازش تصویر و تشخیص الگو از جمله زمینه‌هایی هستند که حل TSP برایشان بسیار راه‌گشاست. TSP، همانطور که از نامش برمی‌آید، عبارت است از یافتن کوتاهترین مسیر بسته ممکن بین N شهر. هدف ما در این مقاله، حل بلادرنگ TSP به کمک شبکه‌های عصبی است. در این مقاله شبکه عصبی جدیدی ارائه شده که می‌تواند به این مسأله در زمان کوتاهی پاسخهای چشمگیری دهد.

تا کنون شبکه‌های عصبی متعددی برای حل TSP ارایه شده است از آنچه می‌توان از شبکه‌های کوهونن [5]، هاپفیلد [8] و Boolean [9] نام برد. در این مقاله تنها دو شبکه کوهونن و هاپفیلد مورد توجه ماست. مدل هاپفیلد دارای دو مشخصه اساسی است، اول اینکه دارای تابع انرژی‌ای است که مشخصات فیزیکی شبکه و رفتار آن را بیان می‌کند و در ثانی به صورت یک فیدبک منفی عمل کرده و در طول آموزش، تابع انرژی سیر نزولی دارد، در حالی که مشخصه اساسی مدل کوهونن روش آموزش رقابتی آن است. هر کدام از مدل‌های کوهونن و هاپفیلد دارای مزایا و معایبی هستند. با این که سرعت همگرایی و دقت کوهونن به مقدار پارامترهایش بستگی دارد ولی در مجموع می‌توان گفت که سرعتش کم است و به همین دلیل نمی‌توان از آن در کاربردهای بلادرنگ استفاده نمود. در مقایسه، مدل هاپفیلد از سرعت قابل قبولی برخوردار است و از این جهت برای استفاده بلادرنگ مناسب است ولی اشکال اساسی آن وجود مینیمم‌های محلی در تابع انرژی‌اش است. متأسفانه این مشکل در شبکه‌هایی که تا کنون برای حل TSP بر اساس این مدل ارایه شده‌اند، حادثه‌هایی باشد. زیرا همانطور که در بخش دو توضیح داده خواهد شد، با این که TSP ذاتاً مسأله‌ای خطی است، ولی تابع انرژی این شبکه‌ها عموماً مجموعی از چند جمله‌ای‌های

درجه دو است (معادله (7)). پس مسئلهای خطی توسط یکتابع درجه دو مدل شده است [4]. به همین دلیل پاسخهای شبکه هاپفیلد چندان معتبر نیست [8]. همچنین در هر جمله تابع انرژی، ثابتی ضرب می شود که بیانگر اهمیت آن جمله نسبت به دیگر جملات تابع انرژی است (ثوابت  $A$  و  $CBA$  در معادله (7)). این ایده به ظاهر ساده، منشأ اشکال اساسی دیگری در مدل هاپفیلد است و آن حساسیت زیاد شبکه به پارامترهای تابع انرژی اش است که با افزایش تعداد شهرهای مسیر بیشتر هم می شود [8].

تا کنون تلاشهای زیادی جهت فرار از مینیممها محلي و یا حذف آنها از تابع انرژی انجام شده است. مثلا در [10] سعی شده است که مینیممها محلي تابع انرژی، با اضافه کردن یک ورودی تصحیح کننده و قابل تطبیق به نزونها، حذف شوند. ولی علی رغم بهبودهای قابل توجه در این زمینه شبکه ها هنوز هم به شدت به پارامترهای تابع انرژی حساس هستند در حقیقت اکثر تلاشهایی که تاکنون در این راه انجام شده است به پیچیده تر شدن تابع انرژی و شبکه، منجر شده است، در حالی که یک راه مناسب برای کم کردن اثر مینیممها محلي، ساده تر کردن تابع انرژی شبکه عصبی است. در این مقاله سعی شده است با تلفیق این دو ایده و ارایه یک شبکه عصبی جدید از قابلیتهای این دو شبکه به صورت توأم استفاده شود، بنابراین شبکه عصبی پیشنهادی مانند کوهونن قابل اعتماد و مانند هاپفیلد سریع است و در عین حال نیاز به تنظیم پارامترهای تابع انرژی نیز ندارد. در بخش بعدی این مقاله تابع انرژی شبکه معرفی می گردد. در بخش سه ساختارش توضیح داده شده است. در بخش چهار نحوه آموزش شبکه بیان شده و همگرایی شبکه اثبات گردیده است. در بخش پنجم نتایج تجربی بدست آمده از شبیه سازی شبکه ارائه شده است. و در بخش آخر جمع بندی مقاله ارائه گردیده است.

## ۲- تابع انرژی شبکه عصبی پیشنهادی

در تمام این مقاله موارد ذیل در نمایش کمیتها رعایت شده اند:

- ۱- درایه واقع در سطر  $i$  ام و ستون  $j$  از ماتریس  $V$  را با  $v_{i,j}$  نشان می دهیم.
- ۲-  $N$  تعداد شهرها،  $d_{i,j}$  فاصله شهر  $i$  ام تا شهر  $j$  ام و  $D$  ماتریس فاصله شهرها از یکدیگر است. هدف ما در این مقاله حل مسئله فروشنده دوره گرد متقارن (Symmetric TSP) است. در STSP فاصله شهر  $i$  ام تا شهر  $j$  ام برابر با فاصله شهر  $j$  ام تا شهر  $i$  ام است. بدیهی است که به این ترتیب  $D$  یک ماتریس متقارن خواهد بود.

$$d_{i,j} = \text{Distance between } i\text{th \& } j\text{th city} \quad i = 1, 2, \dots, N, \quad j = 1, 2, \dots, N \quad (1)$$

$$D = \begin{bmatrix} d_{i,j} \end{bmatrix}_{N \times N} \quad d_{i,j} = d_{j,i}$$

-۳- بردارها و ماتریسها با حروف بزرگ و درایه های آنها با حروف کوچک نشان داده می شوند. علاوه براین بردارها با علامت بردار مشخص می شوند، مانند:  $\bar{X}$ .

-۴- عبارت  $x_k^i$ ، درایه  $k$  ام از بردار خروجی نزون  $i$  ام که در لایه  $I$  ام شبکه واقع است را نشان می دهد. همچنین نزون صفر، همان نزون  $N$  ام و نزون  $N+1$  ام همان نزون اول است.

TSP را می توان مطابق معادله های زیر به صورت یکتابع خطی مدل کرد [4].

$$v_{i,j} = \begin{cases} 1 & \text{If } i\text{th city is located immediately after } j\text{th city} \\ 0 & \text{Otherwise} \end{cases} \quad (2)$$

$$L = \sum_{i=1}^N \sum_{j=1}^N d_{ij} v_{i,j} \quad (3)$$

که  $L$  طول مسیر است. برای اینکه مسیر از هر شهر فقط یکبار بگذرد، باید شرایط ذیل نیز برقرار باشد.

$$\sum_{i=1}^N v_{i,i} = 1 \quad (4)$$

$$\sum_{i=1}^N v_{i,j} = 1 \quad \forall j = 1, 2, \dots, N \quad (5)$$

$$\sum_{j=1}^N v_{i,j} = 1 \quad \forall i = 1, 2, \dots, N \quad (6)$$

طبق روش رایج در حل TSP با استفاده از مدل کوهونن، برای هر شهر از مسیر یک، یا به طور کلی تر، تعداد ثابتی نزون در نظر گرفته می شود و در طول آموزش، وزنهای هر نزون به سمت مختصات شهری که باید جای آن را در مسیر بگیرد، همگرا می شود [5]. در حل TSP به کمک شبکه هایی که بر اساس ساختار هاپفیلد طراحی شده اند، برای هر شهر  $N$  نزون در نظر گرفته می شود و خروجی نزون  $i$  ام از نزونهای وابسته به شهر  $i$  ام زمانی برابر یک است که شهر  $i$  ام در مسیر در محل زام قرار داشته باشد [3][8]. تابع انرژی شبکه نیز برابر با حاصل جمع چندین چند جمله ای درجه دو است که هر کدام از آنها وظیفه شبیه سازی یکی از معادله های (4) تا (6) را بر عهده دارد. معادله زیر، تابع انرژی شبکه ای که Hopfield و Tank برای حل TSP پیشنهاد کردهند را نشان می دهد [8].

$$E = \frac{A}{2} \sum_{x=1}^N \sum_{i=1}^N \sum_{\substack{j=1 \\ j \neq i}}^N v_{x,i} v_{x,j} + \frac{B}{2} \sum_{i=1}^N \sum_{x=1}^N \sum_{\substack{j=1 \\ j \neq x}}^N v_{x,i} v_{y,j} + \frac{C}{2} \left[ \sum_{x=1}^N \sum_{i=1}^N v_{x,i} - N \right]^2 + \frac{D}{2} \sum_{x=1}^N \sum_{\substack{j=1 \\ j \neq x}}^N \sum_{i=1}^N d_{x,y} v_{x,i} (v_{y,j} + v_{y,j-i}) \quad (7)$$

در این معادله، دو جمله اول مانع ایجاد حلقه در مسیر می‌شوند (شرایط معادله‌های (۵) و (۶)، جمله سوم باعث می‌شود تا مسیر از تمام شهرها بگذرد (شرط معادله (۴))، و در نهایت جمله آخر باعث مینیمم شدن طول مسیر می‌شود (شرط معادله (۳)). همانطور که می‌بینید شبیه‌سازی معادله‌های (۴)، (۵) و (۶) درتابع انرژی به پیچیده شدن آن و افزایش شدید مینیمم‌های محلی اش، می‌انجامد. همچنین این کار باعث ورود پارامترهای  $C, B, A$  و  $D$  به تابع انرژی می‌شود که نیاز به مقداردهی اولیه دارد. ما می‌خواهیم تابع انرژی شبکه‌مان تنها شامل معادله (۳) باشد و سایر شرایط مسیر در الگوریتم آموزشی رعایت شود. بنابراین خروجی نرون  $i$  ام در لایه اول شبکه را چنین تعریف می‌کنیم:

$${}^i \vec{X}^1 = \begin{bmatrix} {}^i x'_1 \\ \vdots \\ {}^i x'_N \end{bmatrix} \quad \forall i = 1, 2, \dots, N \quad (8)$$

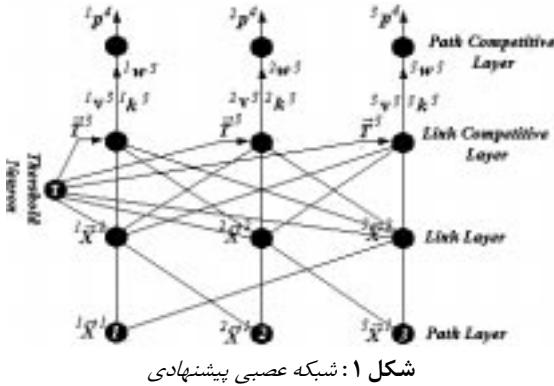
$${}^i x'_j = \begin{cases} 1 & \text{If the city is located at } j\text{th location} \\ 0 & \text{Otherwise} \end{cases} \quad \forall j = 1, 2, \dots, N \quad (9)$$

به این ترتیب تابع انرژی شبکه نیز طبق معادله ذیل تعریف می‌شود (که برابر با طول مسیر است).

$$e = \sum_{k=1}^N \sum_{i=1}^N \sum_{j=1}^N d_{i,j} {}^k x_i^1 {}^{k-1} x_j^1 \quad (10)$$

اندیشه اصلی الگوریتم آموزش چنین است که ابتدا یک مسیر اولیه به شبکه معرفی می‌گردد و شبکه بر اساس آن به مسیر بهینه‌ای همگرا می‌شود، به طوری که در هر مرحله از آموزش - حتی قبل از پایدار شدن شبکه - مسیری که شبکه به ما معرفی می‌کند، معتبر باشد. شبکه باید همانند هاپفیلد به صورت یک فیدبک منفی عمل کند تا در نهایت به یکی از مینیمم‌های محلی تابع انرژی اش برسد.

### ۳- ساختار شبکه عصبی پیشنهاد شده



شکل ۱: شبکه عصبی پیشنهادی

شبکه عصبی پیشنهادی شامل چهار لایه می‌باشد و خروجی نرونهاش به شکل بردار است. شکل ۱ این شبکه را برای سه شهر نشان می‌دهد. در شکل ورودی‌ها، خروجی‌ها و مقادیر آستانه نرونها نیز نشان داده شده‌اند. در این شبکه همانند مدل کوهونن، مسیر در لایه اول (Path Layer) با  $N$  نرون بیان می‌شود ولی وزنهای این نرونها به سمت مختصات شهرها می‌نمی‌کند، بلکه به شهرها اجازه جابجایی در آنها داده می‌شود. معادله‌های (۸) و (۹) عملکرد نرونها این لایه را بیان می‌کنند. لایه دوم (Link Layer) نیز شامل  $N$  نرون است و هر نرون یک کمان از مسیر را مشخص می‌کند، بنابراین داریم:

$${}^i \vec{X}^2 = {}^i \vec{X}^1 + {}^{i+1} \vec{X}^1 \quad (11)$$

در لایه سوم (Link Competitive Layer)، نرون  $i$  نرون داریم. یک نرون، نرون آستانه است. هر کدام از نرونها باقیمانده نظیر یک شهر است (نرون اول نظیر شهر اول، نرون دوم نظیر شهر دوم و ...). معادله (۱۲)، عملکرد نرون آستانه و معادله‌های (۱۳)، (۱۴)، (۱۵) و (۱۶)، عملکرد سایر نرونها این لایه را شرح می‌دهند. در این لایه در هر نرون، بین کمانهای مختلف مسیر، رقابتی شکل می‌گیرد و کمان برنده و وزن آن به عنوان خروجی نرون معرفی می‌شوند.

$$\vec{T}^3 = \left\{ t_k^3 \right\}, \quad t_k^3 = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N d_{i,j} {}^k x_i^2 {}^k x_j^2, \quad k = 1, 2, \dots, N \quad (12)$$

$$X = \begin{bmatrix} {}^1 \vec{X}^2 & {}^2 \vec{X}^2 & \dots & {}^N \vec{X}^2 \end{bmatrix} = \begin{bmatrix} x_{i,j} \end{bmatrix} \quad (13)$$

$$\vec{D}_k = \left\{ d_{k,j} \right\}, \quad d_{k,j} \in D \quad (14)$$

$${}^i \vec{Z}^3 = \vec{D}_i X - \vec{T} \quad , \quad i = 1, 2, \dots, N \quad (15)$$

$$\begin{cases} {}^i v^3 = \min_{j=1}^N ({}^i z_j^3) / x_{i,j} \neq 1 \\ {}^i k^3 = \text{index}({}^i v^3) \end{cases} \quad (16)$$

که تابع  $\text{index}(x)_{\bar{y}}$  درایه عنصر  $x$  از بردار  $\bar{Y}$  را برمی‌گرداند و منظور از " / " عبارت "به طوری که" است.

در لایه چهارم (Path Competitive Layer) نیز  $N$  نرون قرار دارد و همانند لایه سوم هر نرون نظیر یک شهر است (نرون اول نظیر شهر اول، نرون دوم نظیر شهر دوم، ... و نرون  $N$  ام نظیر شهر  $N$  ام). نزونها دارای وزنهای  $(^i w^4, i = 1, 2, \dots, N)$  هستند که در پایان هر مرحله از آموزش با توجه به مسیر جدیدی که شبکه معرفی می‌کند، تغییر خواهد کرد و از این لحاظ شبیه نزونهای شبکه کوہونن هستند. در این باره در بخش بعدی بیشتر صحبت خواهیم کرد. معادله‌های (۱۷)، (۱۸) و (۱۹)، مبین رفتار نزونهای این لایه هستند.

$$(^i v^4 = ^i v^3 - ^i w^4, i = 1, 2, \dots, N) \quad (17)$$

$$k = \begin{cases} \text{index} \left( \min_{i=1}^N (^i v^4) \right) & \min_{i=1}^N (^i v^4) < 0 \\ 0 & \text{Otherwise} \end{cases} \quad (18)$$

$$(^i p^4 = \begin{cases} ^i k^3 & i = k \\ 0 & \text{Otherwise} \end{cases}) \quad (19)$$

در این لایه نزونی که کمترین وزن ( $k$ ) را دارد، برنده می‌شود و خروجی اش، محل جدید شهر همارزش را، در مسیر مشخص می‌کند.

#### ۴-آلگوریتم آموزش شبکه

الگوریتم آموزش شبکه در جدول یک آورده شده است.

جدول ۱: الگوریتم آموزش شبکه

۱. مسیر معتبری را انتخاب می‌کنیم (مسیری معتبر است که در معادله‌های (۴)، (۵) و (۶) صدق کند).

۲. خروجی نزونهای لایه اول را با توجه به مسیر اولیه تعیین می‌کنیم.

۳. وزنهای نزونهای لایه چهارم را طبق معادله (۲۰) تعیین می‌کنیم.

$$(^q w^4 = \sum_{q=1}^N \sum_{i=1}^N \sum_{j=1}^N (d_{i,j} + d_{i,j} - d_{i,j}) {}^q x_i^{1-(q+1)} x_i^{1-(q-1)} x_j^1) \quad (20)$$

۴. اجازه می‌دهیم شبکه یک مرحله آموزش یابد.

۵. شهر نظیر نزون برنده در لایه چهارم را از محل فعلی اش به محل جدیدی که شبکه در خروجی این نزون بیان می‌کند منتقل می‌کنیم. اگر خروجی نزون برنده  $p$  باشد، برنده باید در مسیر، بین دو شهری که کمان  $p$  ام مسیر جاری را تشکیل می‌دهند قرار گیرد.

۶. اگر در لایه آخر نزونی برنده نشده باشد، شبکه پایدار شده است و آموزش شبکه پایان می‌یابد.

۷. مراحل ۳، ۴، ۵ و ۶ را تا آنجا تکرار می‌کنیم که شبکه پایدار شود.

فرض کنید:

۱- مسیری که شبکه در انتهای مرحله  $t$  ام (ابتدا مرحله  $t+1$  ام) آموزش نشان می‌دهد ( $Ph(t)$  و انرژی شبکه در این حالت  $e(t)$  است.

۲- در پایان مرحله  $(t+1)$  ام، نزون  $k$  برنده شده است و خروجی آن  $p$  است.

$$p = {}^k p^4 \quad (21)$$

۳- شهر  $k$ ، در مسیر  $(Ph(t))$  در محل  $p_0$  بوده است.

$$Ph'_{p_0} = k \quad (22)$$

طبق نامعادله  $(e(t+1) \leq e(t))$  (اثبات در ضمیمه ۱)، می‌توان گفت که در طی هر مرحله از آموزش،تابع انرژی سیر نزولی دارد و به این ترتیب شبکه در نهایت به مسیری بهتر از مسیر اولیه (و یا همان مسیر در صورتی که در همان مرتبه اول آموزش نزونی برنده نشود) همگرا می‌شود. با توجه به اینکه در هر مرحله از آموزش شبکه، شهری از یک مکان در مسیر، به مکان دیگری منتقل می‌شود، می‌توان نتیجه گرفت که مسیر نهایی شبکه همان خصوصیات مسیر اولیه‌اش را دارد. یعنی اگر مسیر اولیه از تمام نقاط گذشته باشد، مسیر نهایی نیز از تمام آنها خواهد گذشت و اگر مسیر اولیه به عنوان مثال- سه حلقه داشته باشد، مسیر نهایی نیز سه حلقه خواهد داشت. پس برای حل TSP، اگر مسیر اولیه شبکه معتبر باشد، مسیر نهایی آن نیز معتبر خواهد بود.

#### ۵-نتایج تجربی

شبکه ما در اولین مرحله آموزش نیاز به یک مسیر اولیه معتبر دارد. در حقیقت شرایط معادله‌های (۴)، (۵) و (۶) توسط مسیر اولیه به شبکه اعمال می‌شوند. در این تحقیق شش شیوه مختلف برای تولید مسیر اولیه، شبیه‌سازی شده است:

-۱- مسیر تصادفی

مسیر اولیه به صورت تصادفی انتخاب شود.

#### - ۲- نزدیکترین همسایه

مسیر اولیه چنین بدست می‌آید که ابتدا نقطه‌ای به شکل تصادفی انتخاب می‌شود، سپس نزدیکترین نقطه به آن انتخاب می‌شود و پس از آن نزدیکترین نقطه به نقطه دوم و ... . این کار را تا انجا ادامه می‌یابد که همه نقاط در مسیر قرار گیرند.

#### - ۳- پوسته محدب (Convex Hull<sup>۱</sup>)

در این الگوریتم ابتدا چهار شهر خارجی (خارجی‌ترین شهرها) تشکیل یک مسیر بسته می‌دهند. سپس در هر مرحله فاصله شهرهایی که روی مسیر نیستند تا اضلاع چندضلعی محاسبه می‌شود و شهری که کمترین فاصله را دارد به مسیر اضافه می‌شود. این عمل تا قرار گرفتن تمام شهرها در مسیر ادامه می‌یابد.

#### - ۴- پوسته‌ای براساس بزرگترین چهارضلعی (HTFMDP . Hull Through Four Most Distant Points)

این الگوریتم نیز شبیه الگوریتم قبلی است با این تفاوت که چهار شهر اول، شهرهایی هستند که بیشترین فاصله ممکن را از هم دارند.

#### - ۵- تولید مسیر اولیه بر مبنای شبکه عصبی پیشنهادی (روش اول)

در بخش‌های قبلی ساختار شبکه و نحوه آموزش آن بیان شد. اکنون این شبکه را چنین تغییر می‌دهیم. فرض کنید لایه اول و دوم شبکه،  $m$  نرون ( $m < N$ ) داشته باشند (بنابراین این دو لایه یک مسیر  $m$  شهری را نشان خواهند داد)، لایه سوم شبکه نیز تنها شامل شهرهایی باشد که در مسیر قرار ندارند ( $N-m$  نرون) و لایه چهارم از آن حذف شده باشد. خروجی هر نرون لایه سوم، کمانی از مسیر را معرفی می‌کند که اگر شهر نظیر آن نرون در مسیر- بین دو شهری که کمان را تشکیل می‌دهند قرار گیرد، مسیری با  $m+1$  شهر ایجاد می‌شود به طوری که:

a- مسیر جدید علاوه بر شهرهای قبلی شامل شهر مورد نظر نیز است.

b- این شهر اگر در هر جای دیگر از مسیر قبلی قرار گیرد مسیری طولانی‌تر ایجاد خواهد شد (این مطلب نتیجه مستقیم معادله (۱۶) است).

بنابراین اگر از بین این نرونها، نرونی که کمترین فعالیت را دارد انتخاب کنیم آنگاه به مسیری  $m+1$  شهری می‌رسیم، که طولش از تمام مسیرهای حاصل از جایگذاری شهرهای لایه سوم در مسیر قبلی، کوتاهتر است.

$$k = \min_{i=1}^N \binom{v^3}{i} \quad (23)$$

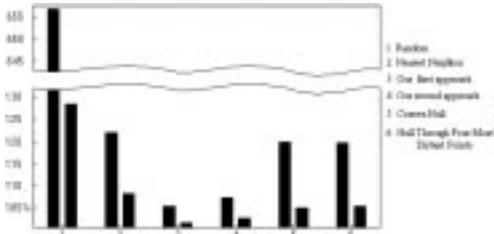
اکنون کافی است که به لایه‌های اول و دوم شبکه یک نرون دیگر اضافه کنیم و شهر برنده را در محلی که در خروجی نرون نظیرش معرفی شده است (فرض کنید خروجی این نرون  $p$  باشد) قرار داده، نرون نظیر این شهر را از لایه سوم حذف کنیم. شهر برنده، به این ترتیب در مسیر قرار می‌گیرد که نرون جدید لایه اول، بین دو نرونی که کمان  $p$  را تشکیل می‌دهند قرار می‌گیرد و خروجی آن طبق معادله ذیل تعیین می‌شود.

$$x_j^I = \begin{cases} 1 & j = k \\ 0 & \text{Otherwise} \end{cases} \quad (24)$$

که  $k$  از معادله (۲۳) بدست آمده است. بنابراین می‌توانیم با شروع از مسیری با تعداد شهرهای کم به یک TSP کامل و معتبر برسیم و سپس آن را به شبکه بدهیم تا بهینه گردد. در اینجا برای شروع از مسیر چهار شهری ای که در الگوریتم سه بیان شد، به عنوان مسیر اولیه استفاده کردہ‌ایم.

#### - ۶- تولید مسیر اولیه بر مبنای شبکه عصبی پیشنهادی (روش دوم)

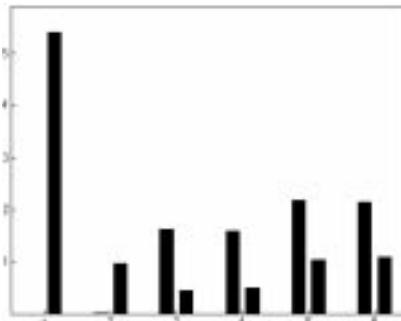
این روش نیز همانند بالاست، با این تفاوت که به جای مسیر چهار شهری الگوریتم سوم، از نظیر آن در الگوریتم چهارم، استفاده شده است.



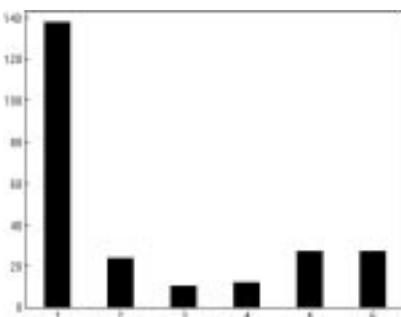
شکل ۲: طول متوسط مسیر اولیه (میله اول هر جفت)، مسیرنهایی شبکه (میله دوم هر جفت) نسبت به طول کوتاهترین مسیر.

برای نشان دادن کارایی شبکه از ۲۰۰ توزیع تصادفی ۱۰ شهری، به کمک شش روشی که بیان شد ۲۰۰ دسته (شش تایی) مسیر اولیه بدست آمد. مسیرهای اولیه هر دسته به شبکه داده شد و برای هر دسته شش مسیر بهینه بدست آمد. بنابراین برای هر توزیع، ۱۲ مسیر بدست آمد. از آنجا که طول مسیرها، وابسته به توزیع شهرهایست، لازم است که قبل از میانگین‌گیری، آنها را نرمال کرد. برای نرمال کردن، طول مسیرهای هر دسته را، بر طول کوتاهترین مسیر همان دسته (که

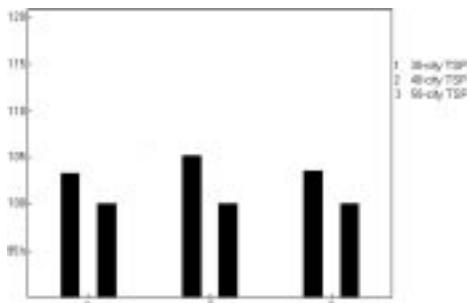
<sup>۱</sup> الگوریتم‌های سه و چهار در [7]. به عنوان دو روش مناسب و سریع برای پاسخ به TSP پیشنهاد شده‌اند.



شکل ۳ : زمان تولید مسیرهای اولیه (میله اول هر جفت)، زمان آموزش شبکه بر حسب ثانیه (میله دوم هر جفت).



شکل ۴ : تعداد فیدبکهای شبکه برای مسیرهای اولیه مختلف



شکل ۵ : طول متوسط مسیرهای پیشنهاد شده توسط شبکه کوهونز (میله اول هر جفت)، طول متوسط مسیرهای شبکه پیشنهادی (میله دوم هر جفت) نسبت به طول کوتاهترین مسیر.



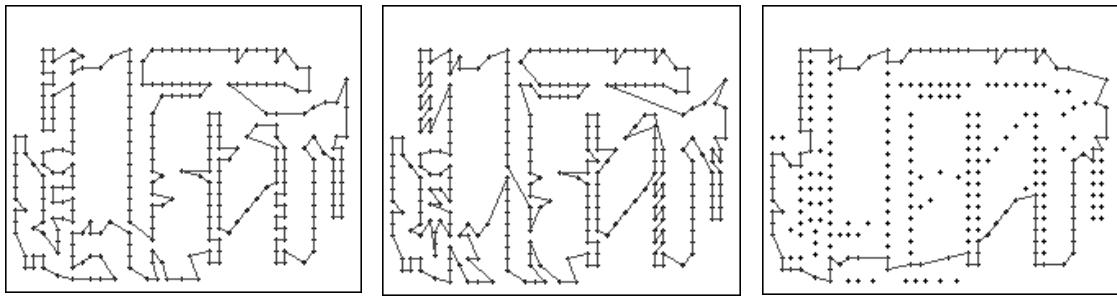
شکل ۶ : زمان همگرایی شبکه کوهونز (میله اول هر جفت)، زمان همگرایی شبکه پیشنهادی بر حسب ثانیه (میله دوم هر جفت).

بهترین پاسخ است، تقسیم کردیم. سپس از طولهای مسیرهای نظری (همه مسیرهای تصادفی اولیه با هم، همه مسیرهای تصادفی بهینه با هم و ...) میانگین گرفته شد. عمل میانگین‌گیری را برای زمانهای همگرایی شبکه (در سیستم Pentium 200 تحت نرمافزار Matlab) و تعداد فیدبکهایش در طول مرحله آموزش (بدون نرمال کردن مقادیر) نیز انجام دادیم. نتایج به ترتیب در شکل‌های ۲، ۳ و ۴ آورده شده است. همانطور که دیده می‌شود پاسخهای شبکه به مسیرهای اولیه‌اش وابسته است. شبکه طول مسیر تصادفی را در ۱۴۰ مرتبه فیدبک به بیش از یک پنجم کاهش داده است و این قدرت شبکه را نشان می‌دهد. بهترین مسیر اولیه و بهترین پاسخها مربوط به مسیرهایی است که از روش پنجم بدست آمده‌اند همچنین مجموع زمان ایجاد مسیر اولیه و همگرایی شبکه، در این روش از بقیه روشها کمتر است. با توجه به اینکه الگوریتم ۵ در حقیقت، از شبکه پیشنهادی منشعب شده است پس می‌توان عملیات مسیریابی شبکه را به دو فاز تقسیم نمود، تعیین مسیر اولیه و بهینه‌سازی آن. بنابراین می‌توان گفت شبکه پیشنهادی، قادر است در زمان کوتاهی بدون نیاز به هیچگونه مقداردهی اولیه‌ای، یک مسیر اولیه مناسب پیشنهاد کرده، آن را بهینه کند.

از الگوریتمهای Convex Hull و HTFMDP در [7] به عنوان دو روش سریع برای حل TSP یاد شده است. همانطور که در شکل ۳ می‌توان دید، سرعت شبکه پیشنهادی، تقریباً با سرعت این دو الگوریتم برابر است در حالی که مسیرهای پیشنهادی اش از مسیرهای بدست آمده از این دو الگوریتم، به اندازه (بیش از) ۱۷٪ طول مسیر بهینه، کوتاهتر است.

شبکه کوهونز به عنوان ابزاری با پاسخهای قابل قبول در حل TSP، شناخته شده است. به منظور تعیین دقت شبکه پیشنهادی در مقایسه با کوهونز، شبکه‌ای که در [5] ارایه شده است را شبیه‌سازی کردیم. برای ۱۰۰ توزیع ۳۰ شهری، ۱۰۰ توزیع ۴۰ شهری و ۱۰۰ توزیع ۵۰ شهری، پاسخهای هر دو شبکه و زمان همگرایی شان بدست آورده شد. پارامترهای شبکه کوهونز چنین انتخاب شدند  $G_0 = \sqrt{30} \text{ } \$$ ،  $\eta_0 = 0.01$  سرعت و  $G_0 = \sqrt{30} \text{ } \$$  که  $\eta_0 = 0.01$  سرعت و پارامتر همسایگی آموزش را مشخص می‌کند. بنابراین نظر نویسنده‌گان [5]، شبکه با این پارامترها، بهترین پاسخها را می‌دهد. طول مسیرها را، با روشی مشابه آنچه قبلاً توضیح داده شد، نرمال کرده، از کمیتهای یکسان (تمام پاسخهای ۳۰ شهری کوهونز با هم، تمام پاسخهای ۴۰ شهری کوهونز با هم و...) میانگین گرفتیم. همچنین از زمانهای همگرایی هر دو شبکه نیز میانگین گرفته شد. نتایج در شکل‌های ۶ و ۷ نشان داده شده است. همانطور که در شکل ۶ می‌بینید شبکه کوهونز بسیار کند است به طوری که سرعت همگرایی اش با شبکه پیشنهادی قابل مقایسه نیست. نمودار شکل ۵ نیز حاکی از آن است که تقریباً در تمام موارد مسیرهای شبکه پیشنهادی کوتاهتر بوده است، زیرا در شکل ۵، همه میله‌های مربوط به شبکه پیشنهادی، تقریباً ۱۰۰٪ را نشان می‌دهند. مسیرهای پیشنهادی کوهونز به طور متوسط به اندازه (بیش از) ۲/۵٪ طول مسیر بهینه، بلندتر بوده‌اند.

در شکل ۷ مسیر حاصل از آنگوریتم ۵ پس از ۱۰۰ مرتبه تکرار، برای یک توزیع ۲۸۰ نقطه‌ای که در حقیقت نقشه یک PCB [11] است، نشان داده شده است. همچنین مسیر اولیه و نهایی شبکه پیشنهادی (برای همان توزیع) نیز در شکل‌های ۸ و ۹ نشان داده شده‌اند.



شکل ۷: مسیر حاصل از آنگوریتم ۵ پس از ۱۰۰ مرتبه تکرار.  
شکل ۸: مسیر اولیه پیشنهاد شده با استفاده از آنگوریتم ۵.  
شکل ۹: پاسخ شبکه پیشنهاد شده با اولیه شکل ۸.

#### ۶- جمع‌بندی

در این مقاله شبکه عصبی‌ای پیشنهاد شده است که با سرعت قابل قبولی پاسخهای مناسبی به مسئله فروشنده دوره‌گرد می‌دهد. شبیه‌سازی‌های انجام شده دلیلی بر این مدعای است. با اینکه تابع انرژی شبکه پیشنهادی تنها شامل یک جمله است اما هنوز هم دارای مبنی‌مهم‌های محلی است و همین امر باعث حساسیت شبکه به مسیرهای اولیه‌اش شده است، گرچه که این مشکل با ارایه روش‌های تولید مسیر اولیه، برمبنای شبکه پیشنهادی، به شکل چشمگیری حل شده است. از این شبکه می‌توان علاوه بر کاربردهای بلادرنگ برای حل TSP‌های بسیار بزرگ نیز استفاده کرد. قدرت این شبکه در ساختار فیدبکی-رقابتی آن است که این دو خاصیت اجازه انعطاف زیادی به شبکه می‌دهد. دیگر قابلیت مهم این شبکه، این است که می‌توان به کمک مسیر اولیه، شرایط بسیار پیچیده‌ای را در مسیر شبیه‌سازی نمود. از این ابزار می‌توان برای حل طیف وسیعی از مسایل بهینه‌سازی ترکیبی استفاده کرد.

#### ۷- قدردانی

این مقاله حاصل تلاشی است که در گروه روباتیک دانشگاه فردوسی و با مساعدت هسته علمی بسیج دانشجویی دانشکده مهندسی، آغاز شده بود. در اینجا از دست اندکاران بسیج دانشجویی دانشگاه فردوسی، قدردانی و تشکر می‌شود.

#### ۸- مراجع

- [1] S. Haykin, “Neural Networks”, New York, Macmillan College Pub., 1994 .
- [2] P. Crescenzi, V. Kann, “A Compendium of NP optimization problems”, [http://www.zvne.fer.hr/~zmija/resources/science\\_resources/nn\\_for\\_optimization/index.html](http://www.zvne.fer.hr/~zmija/resources/science_resources/nn_for_optimization/index.html)
- [3] M. K. Mehmet Ali, F. Kamoun, “Neural Networks for Shortest Path Computation and Routing in Computer Networks”, IEEE Trans. Neural Networks, VOL. 4, NO. 6, Nov. 1993 .
- [4] K. Smith, “An Argument for Abandoning the Traveling Salesman Problem as a Neural Network Benchmark”, IEEE Trans. Neural Networks, VOL. 7, NO. 6, Nov. 1996 .
- [5] S. J. Kim, H. M. Choi, “An Efficient Algorithm for Traveling Salesman Problems based on Self-Organizing Feature Mars”, 2th IEEE Int. Conference on Fuzzy Systems, Mar. 1993.
- [6] K. Shinozawa, T. Uchiyama, K. Shimohara, ”An Approach for Solving Dynamic TSPs using Neural Networks”, IJCNN, Nov. 1991 .
- [7] O. Lahyani, E. Oertli, H. Eberle, “Optimizing Drill Tapes for Printed Circuit Boards”, WAC, Vol.3, May 1996 .
- [8] S. M. Gowda, B. W. Lee ,B. J. Sheu, ”An Improved Neural Network Approach to the Traveling Salesman Problem”, TENCON, Nov. 1989 .
- [9] S. Bhide, N. John, M. R. Kabuka, ”A Real-Time solution for the Traveling Salesman

- Problem using a Boolean Neural Network”, ICNN, Mar. 1993 .
- [10] B. W. Lee, B. J. Sheu, “Modified Hopfield Neural Networks for Retrieving the Optimal Solution”, IEEE Trans. Neural Networks, VOL. 2, NO. 1, Jan. 1991 .
- [11] TSPLIB, <http://softlib.rice.edu/softlib/tsplib>

## ضمیمه ۱

می خواهیم نامعادله  $e(t+1) \leq e(t)$  را اثبات کنیم. از (۲۵) و (۲۱)، معادله (۲۵) و از (۱۲) و (۱۵)، معادله (۲۶) نتیجه می شود.

$$\begin{cases} {}^k v^3 = {}^k z_p^3 \\ {}^k k^3 = p \end{cases} \quad (25)$$

$${}^k z_p^3 = \sum_{j=1}^N d_{k,j} {}^p x_j^2 - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N d_{i,j} {}^p x_i^2 {}^p x_j^2 \quad (26)$$

از معادله (۱۱) و دو معادله قبل نتیجه می شود:

$${}^k v^3 = \sum_{j=1}^N d_{k,j} \left( {}^p x_j^I + {}^{p+I} x_j^I \right) - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N d_{i,j} \left( {}^p x_i^I + {}^{p+I} x_i^I \right) \left( {}^p x_j^I + {}^{p+I} x_j^I \right) \quad (27)$$

$${}^k v^3 = \sum_{i=1}^N \sum_{j=1}^N \left( d_{k,j} + d_{k,i} \right) {}^p x_j^I {}^{p+I} x_i^I - \sum_{i=1}^N \sum_{j=1}^N d_{i,j} {}^p x_i^I {}^{p+I} x_j^I \quad (28)$$

$${}^k v^3 = \sum_{i=1}^N \sum_{j=1}^N \left( d_{k,j} + d_{k,i} - d_{i,j} \right) {}^p x_i^I {}^{p+I} x_j^I \quad (29)$$

می دانیم که شهر  $w$  در محل  $p_0$  مسیر  $Ph(t)$  است. پس از (۲۰) و (۲۹) معادلات ذیل بدست می آیند.

$${}^k w^4 = \sum_{i=1}^N \sum_{j=1}^N \left( d_{k,j} + d_{k,i} - d_{i,j} \right) {}^{(p_0+I)} x_i^I {}^{(p_0-I)} x_j^I \quad , \quad {}^{p_0} x_k^I = I \quad (30)$$

$${}^k v^4 = \sum_{i=1}^N \sum_{j=1}^N \left[ \left( d_{k,j} + d_{k,i} - d_{i,j} \right) {}^p x_i^I {}^{p+I} x_j^I \right] - \left[ \left( d_{k,j} + d_{k,i} - d_{i,j} \right) {}^{p_0+I} x_i^I {}^{p_0-I} x_j^I \right] \quad (31)$$

فرض کنید در مسیر  $Ph(t)$  داشته باشیم:

$$Ph'_{p_0-I} = a \quad (32)$$

$$Ph'_{p_0+I} = b \quad (33)$$

$$Ph'_p = c \quad (34)$$

$$Ph'_{p+I} = d \quad (35)$$

بنابراین با توجه به (۱۸) می توان معادلات ذیل را نتیجه گرفت.

$${}^k v^4 = \left( d_{k,c} + d_{k,d} - d_{c,d} \right) - \left( d_{k,a} + d_{k,b} - d_{a,b} \right) < 0 \quad (36)$$

$$d_{k,c} + d_{k,d} + d_{a,b} < d_{k,a} + d_{k,b} + d_{c,d} \quad (37)$$

انرژی شبکه در مرحله  $t$  ام آموزش برابر است با:

$$e(t) = \left[ \sum_{q=I}^N \sum_{i=1}^N \sum_{\substack{j=1 \\ q \neq p_0, p_0+I, p+I}}^N d_{i,j} {}^q x_i^I {}^{(q-I)} x_j^I \right] + d_{k,a} + d_{k,b} + d_{c,d} \quad (38)$$

$$e(t) = C_1 + d_{k,a} + d_{k,b} + d_{c,d} \quad (39)$$

انرژی شبکه در مرحله  $(t+1)$  ام نیز به روش مشابه محاسبه می شود.

$$e(t+1) = C_2 + d_{k,c} + d_{k,d} + d_{a,b} \quad (40)$$

تفاوت دو مسیر  $Ph(t+1)$  و  $Ph(t)$  در مکان شهر  $k$  است. در  $Ph(t)$  بین  $a$  و  $b$  قرار دارد در حالی که در  $Ph(t+1)$  بین  $c$  و  $d$  قرار گرفته است. اگر از مسیر  $Ph(t)$  کمانهای  $(a,k)$  و  $(k,b)$  حذف شوند و کمانهای  $(c,k)$  و  $(k,d)$  به آن اضافه گردند، مسیر  $Ph(t+1)$  حاصل می شود. بنابراین سایر قسمتهای این دو مسیر مشترکند.  $C_1$  و  $C_2$  برابر با طول همین قسمتهای هستند، پس با هم برابر هستند. بنابراین از معادله های (۳۷)، (۳۹) و (۴۰) می توان نامعادله بالا را نتیجه گرفت.