

# ارائه یک مدل شبکه عصبی LVQ ضربانی برای پردازش دادگان پویا

|                          |                            |
|--------------------------|----------------------------|
| ناصر مزینی               | اکرم بیگی                  |
| استادیار                 | کارشناس ارشد               |
| دانشکده مهندسی کامپیوتر  | دانشکده مهندسی کامپیوتر    |
| دانشگاه علم و صنعت ایران | دانشگاه علم و صنعت ایران   |
| mozayani@iust.ac.ir      | akrambeigi@comp.iust.ac.ir |

**چکیده:** محققین بسیاری سعی کرده اند تا با اعمال نرونهای ضربانی به شبکه های عصبی کلاسیک کارایی آنها را در پردازش اطلاعات زمانی افزایش داده و شباهت آنها را به شبکه های عصبی بیولوژیک بیشتر کنند. در این راستا یکی از شبکه های عصبی کلاسیک که تا کنون به شیوه ضربانی مدل نشده است، شبکه "Learning Vector Quantization" یا LVQ است. ما بر آن شدیم تا علاوه بر طراحی و پیاده سازی ضربانی این شبکه، تمهیداتی را به کار بگیریم که نسبت به بعضی از شبکه های ضربانی که تا کنون پیاده سازی شده اند، از جهاتی بهبود داشته باشیم. ما مدل خویش را پس از طراحی و پیاده سازی به یک سیستم «تشخیص امضای پویا» که در آن نقش اطلاعات زمانی از اهمیت ویژه ای برخوردار است اعمال کرده و نتایج جالب توجهی بدست آوردیم.

**کلمات کلیدی:** شبکه عصبی ضربانی، شبکه عصبی LVQ، شبکه LVQ ضربانی، قطار ضربه، تشخیص امضای پویا.

## ۱-مقدمه

یکی از ایرادهایی که بر شبکه های عصبی کلاسیک وارد شده است، فقدان جایگاه ویژه ای برای فاکتور زمان وقوع رخدادها در این شبکه هاست. در تحقیقات بیولوژیکی از ساختار نرونهای مغز مشخص شده است که علاوه بر میزان تحریک ورودی و موقعیت داخلی هر نرون، زمان وقوع تحریکها و ترتیب زمانی آنها نقش بسیار مهمی در پردازشهای عصبی ایفا می کند [۱]. بنابر وجود این نقیصه در مدل‌های کلاسیک و به منظور شبیه تر کردن شبکه های عصبی مصنوعی به شبکه های عصبی واقعی، با بکاربردن نرونهای ضربانی شبکه های عصبی ضربانی ایجاد شدند [۲]. یک ویژگی بارز نرونهای ضربانی داشتن قابلیت ذخیره مشخصات فضایی- زمانی الگوها می باشد. بنابراین، قویتر از هم نوعهای کلاسیک خود عمل می کنند و غنی تر می شوند و در بسیاری از کاربردها نسبت به شبکه های کلاسیک از برتری قابل توجهی برخوردارند [۳].

در نتیجه تحقیقات بیولوژیک، مشخص شده است که نرونها فعالیت خود را بصورت ضربه ای بوسیله یک سیگنال مقدار گسسته و زمان پیوسته (در حقیقت بصورت ایجاد پالس) ارائه می کنند. دنباله ای از فعالیت‌های

<sup>1</sup> Spiking Neurons

<sup>2</sup> Spatio-Temporal

پتانسیلی که توسط یک نرون ایجاد می شود قطار ضربه نامیده می شود. از آنجا که تمام ضربه های ایجاد شده توسط یک نرون کاملاً شبیه به یکدیگر می باشند، بنابراین شکل آنها حاوی اطلاعات خاصی نمی باشد و آنچه که اهمیت دارد تعداد و زمان تولید ضربه ها در نرون می باشد [۱].

روشهای زیادی برای بکار بردن اطلاعات زمانبندی ضربه در محاسبات عصبی وجود دارد. عمومی ترین حالت های آن دو مدل پاسخ ضربه و مدل تجمع و شلیک می باشند که هر دو مصداقی از مدل عمومی شلیک حد آستانه هستند [۴]. در ادامه ما به بیان ویژگیهای شبکه LVQ کلاسیک که پیش از این به فرم ضربانی مدل نشده بود و بدنبال آن به معرفی شبکه LVQ ضربانی پیشنهادی خود می پردازیم.


## ۲- شبکه LVQ کلاسیک

ساختار یک شبکه عصبی LVQ در شکل ۱ نشان داده شده است. الگوریتم LVQ یک روش دسته بندی الگو را بیان می کند که در هر واحد خروجی بیانگر یک دسته یا گروه ویژه است و دارای خواص زیر می باشد [۵ و ۶]:

✓ این شبکه یک شبکه رقابتی است که به سادگی می تواند مورد استفاده قرار گیرد و در بسیاری از مسائل به خوبی کار می کند. همچنین یک شبکه رقابتی استاندارد تنها می تواند نواحی تصمیم گیری محذب ایجاد نماید اما شبکه LVQ بر این محدودیت فائق می آید.

✓ جهت محاسبه میزان نزدیکی بردار ورودی و بردارهای وزن، فاصله بین دو بردار بطور مستقیم محاسبه می شود و مزیت آن این است که نیازی به نرمالیزه نمودن بردارها نمی باشد.

آموزش واحدهای خروجی بوسیله تطابق و تعدیل وزنهاشان با آموزش نظارت شده انجام می گیرد. در این الگوریتم فرض می شود که مجموعه الگوهای آموزشی با کلاس بندی مشخص، با یک توزیع اولیه بردارهای مرجع که هر کدام یک کلاس بندی مشخص را ارائه می کنند، فراهم باشد. بعد از آموزش یک شبکه LVQ یک بردار ورودی را بوسیله نسبت دادن آن به همان کلاس بصورت واحد خروجی که بردار وزن آن به بردار ورودی نزدیکترین باشد، کلاس بندی می کند.



شکل ۱- ساختار شبکه LVQ

هر واحد خروجی نمایانگر یک کلاس مشخص است.  $X_i (1 \leq i \leq n)$  نرونهای لایه ورودی و  $Y_j (1 \leq j \leq m)$  نرونهای لایه خروجی و همچنین  $W_{ij}$  ها بردارهای وزن شبکه می باشند و نرونهای ورودی و خروجی اتصال کامل دارند.

<sup>1</sup> Spikes

<sup>2</sup> Spike Train

<sup>3</sup> Spike Response Model

<sup>4</sup> Integrate and Fire Model

<sup>5</sup> Competitive

<sup>6</sup> Fully Connected

### ۳- شبکه LVQ ضربانی


ما بر مبنای ماهیت و ساختار شبکه LVQ کلاسیک مدل شبکه خود را ایجاد کرده ایم. این مدل شبکه برای دسته بندی الگوهایی که یکی از وجوه متمایز کننده آنها زمان وقوع رخدادها باشد، سودمند است [۷].

### ۴- ساختار شبکه LVQ ضربانی

شبکه ضربانی ما یک مدل رقابتی و پیشخور است که مشتمل بر دو لایه ورودی و خروجی می باشد. لایه ورودی شبکه شامل  $n$  نرون ورودی است و هر نرون لایه خروجی نماینده یک کلاس یا دسته است بنابراین به تعداد کلاسها یا دسته ها، لایه خروجی دارای  $m$  نرون می باشد. نرونهای لایه ورودی با نرونهای لایه خروجی شبکه بصورت اتصال کامل با هم مرتبط هستند. پس از آموزش شبکه، پاسخ شبکه به ورودیهای آزمون یک برنده غالب (WTA) می باشد. به این معنا که فقط یکی از کلاسها برنده خواهند شد و نرونهای لایه خروجی بطور همزمان شلیک نخواهند کرد.

### ۴-۱ ورودی شبکه LVQ ضربانی

هر ورودی شبکه شامل  $n$  دنباله ضربان یا قطار پالس است و مقدار هر ضربه قطار پالس هر مقدار حقیقی بین صفر و یک را می تواند به خود اختصاص دهد. این مزیت نسبت به شبکه های با ورودی باینری، در مدل ما وجود دارد. ورودی شبکه LVQ ضربانی سیگنالهایی با طول پنجره زمانی ثابت است. البته لازم به ذکر است که برای شبکه LVQ ضربانی در حالت عمومی لازم نیست طول پنجره ثابت باشد. بنابراین در عمل ورودی شبکه، سیگنالهایی با مقادیر ضربه بین صفر و یک در یک بازه زمانی ثابت است. نمایی از یک سیگنال ورودی شبکه در شکل ۲ آمده است:



شکل ۲- نمونه ای از قطار ضربه ورودی شبکه

$t_0$  زمان شروع سیگنال و  $T$  زمان خاتمه آن می باشد. بنابراین در نهایت ورودی شبکه شامل  $n$  سیگنال فضایی-زمانی از نوع شکل ۲ برای هر نمونه ورودی می باشد که هر کدام از این سیگنالها به نرون ورودی متناظر اعمال می شوند. و هر بردار  $X$  که خود دارای  $n$  مؤلفه  $(x_1, \dots, x_i, \dots, x_n)$  می باشد نشانگر یک نمونه ورودی است.

### ۴-۲ وزن اتصالات شبکه LVQ ضربانی

شبکه LVQ ضربانی ما شامل  $m$  بردار وزن  $W_j (1 \leq j \leq m)$  برای  $m$  نرون لایه خروجی می باشد. هر  $W_j$  بیانگر بردار وزن متناظر با  $j$  امین واحد خروجی است. هر بردار  $W_j$  خود شامل  $n$  مؤلفه  $(w_{1j}, \dots, w_{ij}, \dots, w_{nj})$  است و هر  $w_{ij}$  وزن اتصال بین نرون ورودی  $i$  و نرون خروجی  $j$  می باشد. در مدل ما مؤلفه های وزن شبکه با در نظر گرفتن فرم ورودی، بصورت بردارهایی با زمان شروع صفر و طول ثابت  $T$  می باشند.

در ابتدای آموزش شبکه، به مؤلفه های وزن را مقدار اولیه می دهیم. در حین آموزش بردارهای وزن به سمت بردار مرجع همگرا می شود. در پایان آموزش برای آزمون نمونه های آزمایش بردارهای وزن ثابت می مانند.

### ۵- آموزش شبکه LVQ ضربانی

در ابتدای کار وزنهای مربوط به هر یک از نرونهای لایه خروجی - که هر یک نماینده یا شاخص یک کلاس یا دسته هستند - را با بردار ورودی مربوط به همان کلاس مقدار دهی اولیه می کنیم. پس از آن در هر دوره از آموزش شبکه به ازای هر یک از نمونه های مجموعه آموزشی کارهای زیر انجام می شود:

<sup>1</sup> Winner Take All

<sup>2</sup> Epoch

<sup>3</sup> Training Set

- یک به یک بردارهای نمونه های ورودی شبکه ( نمونه های آموزش) را به شبکه اعمال می شود. نرونهای ورودی می توانند حد آستانه شلیک داشته باشند و عمل فیلترینگ را روی داده های ورودی انجام داده یا از این قابلیت استفاده نکنند که انتخاب این امر به نوع کاربرد شبکه در حل مسائل مختلف بستگی دارد.
- مرحله بعدی به یافتن اختلاف یا فاصله بردار ورودی با بردارهای وزن اختصاص دارد.
- سپس با توجه به اینکه بردار ورودی متعلق به کدام کلاس یا دسته است یعنی کدام نرون خروجی باید با اعمال این ورودی شلیک کند، وزنه های مربوط به آن کلاس اصلاح می شود.
- در پایان عملکرد هر دوره آموزش نرخ یادگیری کاهش می یابد و شرط توقف الگوریتم بررسی می شود.

## ۶- قانون اصلاح وزن در شبکه LVQ ضربانی

در راستای بدست آوردن یک قانون اصلاح وزن مناسب و هماهنگ با شبکه ای که ساختار آن را پیشنهاد شده است، ابتدا روشی که مطرح کردیم بر اساس نوع نگاه ما به مقوله قطارهای ضربانی بنا شده بود. این روش (روش اول)، شیوه جالب و کارایی برای کاربردهایی نظیر سیستم تشخیص امضای پویا می باشد. اما پیاده سازی آن نیاز به برنامه نویسی در سطح بالایی دارد. به همین دلیل ما روش کارا و مطلوب دیگری (روش دوم)، را مطرح کرده ایم:

### ۶-۱ روش اول

- در این روش سعی بر حذف نویزهای مربوط به اطلاعات ورودی شبکه است.
- حاصل برآیند هر دو ضربه متناظر، ضربه ای با مقدار میانگین حاصل از آن دو ضربه است.
- در تعدیل بردارها اولویت با بردار وزن است.
- هرچه تعداد دوره ها افزوده شود، نرخ یادگیری و در نتیجه ضریب تأثیر بردار ورودی روی بردار وزن کم می شود. و نرخ یادگیری با افزایش تعداد دوره ها به سمت صفر میل می کند. بدین ترتیب بردارهای وزن پس از چند دور به ثبات می رسند.
- به ازای هر دو ضربه اضافی در یکی از قطارهای ضربه، یک ضربه در قطار برآیند تعدیل می شود. به این معنی که اگر اضافی باشند، یکی از آنها کم می شود و یا اگر کم باشند، متناظراً یکی به آنها اضافه می شود.


### ۶-۲ روش دوم

وزنه های کلاس برنده شده به این صورت اصلاح می شود که هر یک از مؤلفه های وزن کلاس برنده متناظراً با مؤلفه های نمونه ورودی تعدیل می شود. به بیان دیگر گفته شد که هر یک از نمونه های ورودی دارای  $n$  مؤلفه است که هر یک از این مؤلفه ها یک سیگنال فضایی- زمانی است که به  $n$  نرون لایه ورودی شبکه اعمال می شوند. از طرف دیگر نرون برنده در لایه خروجی نیز دارای  $n$  مؤلفه از همان نوع سیگنال با طول ثابت است. حال برای تعدیل وزن از هر جفت متناظر از این دو دسته مؤلفه میانگین وزنی گرفته می شود. یعنی از مقدار هر یک از ضربانهای بردار اول از ورودی جاری نظیر به نظیر با مقدار عددی بردار اول وزن نرون کلاس برنده شده، میانگین وزنی گرفته می شود. در این راستا رابطه زیر را که بیانگر این اصلاح وزن می باشد پیشنهاد می کنیم:

$$w_{ij}(new) = \left\{ \frac{w_{ij}(old) + x_i(t) \times \alpha}{(1 + \alpha)} \mid 1 \leq i \leq n, t_0 \leq t \leq T \right\} \quad (1)$$

در این رابطه مشخص کننده نرون برنده و  $t$  بیانگر هر یک از برشهای زمانی بین  $t_0$  زمان شروع سیگنال و  $T$  زمان خاتمه آن است.  $\alpha$  فاکتور نرخ یادگیری است که کاهش آن در انتهای هر دوره باعث می شود نرخ یادگیری کاهش یابد. در این مدل ما برای کاهش مقدار  $\alpha$ ، یک رابطه خطی لحاظ کرده ایم. نمونه ای از این اصلاح وزن برای دسته های ۴ تایی بردار ورودی و بردار وزن در شکل ۳ و ۴ نشان داده شده است. بردارهای  $x$ ، ورودی و بردارهای  $w$

بردارهای وزن هستند. بردارهای  $w'$  نیز بردارهای وزن تعدیل شده هستند. در ادامه هر جا که سخن از قانون اصلاح وزن به میان می آید، استفاده از «روش دوم» مورد نظر است.




شکل ۴- اصلاح وزن به روش دوم

شکل ۳- اصلاح وزن به روش اول

### ۷- قانون مقایسه دو بردار در شبکه LVQ ضربانی

در این مدل برای بدست آوردن اختلاف دو بردار از مجموع اختلافات ضربه های نظیر به نظیر بین دو بردار استفاده می کنیم. تمهیدی که در مدل های ضربانی بررسی شده پیشین لحاظ نشده بود و ما لحاظ کردیم، این است که:

- اینکه کدام دو مقدار ضربان متناظر یکدیگر هستند، بسته به نوع مسأله و چگونگی کاربرد شبکه LVQ ضربانی برای حل آن متفاوت است. بعنوان مثال شروع دو سیگنال می تواند همزمان نباشد و این مدل در صورت مقدار دهی به پارامترهای مربوطه می تواند دو سیگنال یکسان را که تنها چند برش زمانی در شروع اختلاف دارند، یکسان تشخیص دهد.
- مورد دیگر این است که با مقدار دهی پارامترهای مربوطه بنابر کاربرد شبکه در هر مسأله، اگر تعداد ضربانهای متوالی و مشابه یکدیگر در یک سیگنال فضایی- زمانی  $p$  و در دیگری  $q$  باشد و  $p$  و  $q$  تعداد اختلاف کمتر از پارامتر مربوط که به آن بازه تشابه می گوئیم، داشته باشند آن دو سیگنال را نیز یکسان معرفی کند. این موضوع در شکل ۵ نشان داده شده است. در شکل ۵ به شرط مقدار دهی پارامترهای مربوطه، مدل شبکه می تواند بردارهای  $v_1$  و  $v_2$  و به همین ترتیب بردارهای  $v_3$  و  $v_4$  را یکسان تشخیص دهد.



شکل ۵- تشخیص یکسان بردارها ( بازه تشابه)

### ۸- آزمون شبکه LVQ ضربانی

پس از اینکه آموزش شبکه به اتمام رسید، برای آزمون شبکه به این طریق عمل می کنیم که هر کدام از نمونه های ورودی متعلق به مجموعه آزمون به نرونهای لایه ورودی شبکه LVQ ضربانی اعمال می شوند. آنگاه بردارهای

مربوط به هر نمونه با تمام بردارهای وزن مقایسه می شوند. و در نتیجه تنها نرونی از لایه خروجی برنده خواهد شد که بردار وزن آن نرون کمترین اختلاف را با بردارهای نمونه ورودی داشته باشد. آنگاه نرون برنده یکبار شلیک می کند.

## ۹- جمع بندی

شبکه LVQ کلاسیک یکی از شبکه های رقابتی است که تا کنون با نرونهای ضربانی مدلسازی نشده بود. سعی ما بر این بود که با وجود تبدیل نوع کلاسیک آن به ضربانی، ویژگیهای مهم آن را حفظ کنیم. در این شبکه زمان وقوع هر ضربان نقش اساسی در کارکرد شبکه دارد. اینکه زمان هر رخداد مستقیماً در کارکرد این شبکه دخیل است یک نکته مثبت به شمار می آید. همچنین اینکه از خود قطارهای ضربه استفاده می شود باعث می شود که اطلاعات مسأله تا حدود زیادی حفظ شود. همچنین امکان مانور روی نوع داده های ورودی شبکه و نوع پذیرش آنها به عنوان یک دسته یا کلاس همسان نیز از نکات مثبت می باشد.

در نهایت پس از طراحی و پیاده سازی ما شبکه خود را با سیستم تشخیص امضاء پویا آزمایش کردیم [۸]. در این سیستم ورودیهای شبکه از اطلاعات مربوط به هر جابجایی قلم و زمان آن در هر امضاء، بدست می آید. با بکار بردن این شبکه در کاربرد تشخیص امضاء پویا توانستیم به برخی از محدودیتها پاسخ بهتری دهیم. بعنوان مثال ممکن است یک امضاء با اندکی تأخیر از زمان شروع ثبت شود و این امر نباید خللی به تشخیص درست آن امضاء در کلاس مربوطه وارد کند، و یا اندکی تغییر در بزرگی یا کوچکی امضاء نباید تغییری در نتیجه تشخیص شبکه داشته باشد که مدل ما قادر است این مشکلات را برطرف کند و برای تشخیص امضای اصلی از جعلی بدلیل استفاده همزمان از اطلاعات زمانی و مکانی روش کارایی می باشد.

در آزمایش اول به ۱۰٪ کارایی و با اعمال محدودیت بیشتری در آزمایش دوم به ۹۳٪ صحت دست یافتیم.

## ۱۰- مراجع:

- [1] W. Gerstner & W. Kistler . “ Spiking Neuron Models , Single Neurons Populations Plasticity ”. Cambridge University. First Edition 2002.
- [2] J. Vreeken . “Spiking Neural Networks, an introduction ” . Adaptive Intelligence Laboratory, Intelligence System Group, Institute for Information and Computing Sciences, Utrecht University . 2003.
- [3] N. Mozayyani & V. Alanuo & J. F. Dreyfus & G. Vaucher . “ A Spatio-Temporal Data-Coding Applied To Kohonen Maps ”. ICANN vol. 2, pp. 75-79. France . Oct. 1995.
- [4] A. Lerchner . “Spike – Response – Model Neuron ” . Biology to Technical Neural Networks , E01. October 2001.
- [5] D. W. Patterson. . “ Artificial Neural Networks ”. Prentice Hall Publishers. 1998.
- [6] B. D. Ripley . “ Pattern Recognition and Neural Networks”. University of Oxford. Cambridge University Press. Fifth Published 2001.

[۷] ا. بیگی . “ اعمال نرونهای ضربانی به مدل‌های کلاسیک شبکه های عصبی مصنوعی ”. پروژه کارشناسی ارشد. دانشکده کامپیوتر. دانشگاه علم و صنعت ایران. ۱۳۸۲.

[۸] ا. بیگی . “ سیستم تشخیص امضای پویا با شبکه عصبی ”. دهمین کنفرانس سالانه انجمن کامپیوتر ایران. صص ۱۷ تا ۲۳ ، ۱۳۸۳.