

# بررسی کاربردی شبکه عصبی پالس همراه در پردازش تصویر

ستاره فرامرزپور\*

دانشجوی کارشناسی ارشد هوش مصنوعی، مجتمع فناوری اطلاعات، ارتباطات و امنیت، دانشگاه صنعتی مالک اشتر، تهران  
پست الکترونیکی: faramarzpour2005@gmail.com

مهدی حسنی

کارشناس ارشد مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه صنعتی شریف، تهران  
پست الکترونیکی: mh.hassani@yahoo.com

## چکیده

شبکه عصبی پالس همراه موضوع تحقیقاتی مورد توجه در زمینه هوش مصنوعی است. این شبکه در الگوریتم‌های برنامه‌های مختلف مانند قطعه‌بندی، افزایش، همجوشی، استخراج ویژگی، تشخیص لبه، برطرف کردن نوفه، تشخیص الگو، رمزگشایی، نازک شدن تصویر و ... استفاده شده است. شبکه عصبی پالس همراه از قشر بینایی پستانداران الهام گرفته است و با توجه به خروجی همزمان پالس آن، آستانه قابل تنظیم و کنترل پارامترهای دیگر نسبت به دیگر شبکه‌های عصبی منحصر به فرد است. شبکه‌های عصبی پالس همراه دارای ویژگی‌های قابل توجهی برای پردازش تصویر و عملکرد بالقوه‌ای در قطعه‌بندی تصویر است. با این حال دقت و صحت کار شبکه بستگی زیادی به مقادیر پارامترهای شبکه دارد. دو ویژگی اساسی شبکه، استفاده از پالس و سازوکار ساده حوزه ارتباطی اتصال آن است. شبکه عصبی پالس همراه مدولاسیونی نامتقارن از یک ورودی به نورون‌های دیگر است. در این شبکه انتخاب یک جفت نورون تعدیلی به جای یک جفت نورون افزودنی سبب فعال شدن یک نورون با ورودی اولیه توسط یک جفت ورودی است که این امر یکی از ویژگی‌های مهم در پردازش تصویر است. در این مقاله به معرفی این شبکه عصبی و برخی کاربردهای آن در پردازش تصویر پرداخته شده است.

واژگان کلیدی: شبکه عصبی پالس همراه، پردازش تصویر، قطعه‌بندی تصویر.

## 1- مقدمه

تحقیقات الهام گرفته از سیستم بینایی از سال 1950 شروع شد، Huxley و Hodgkin در سال 1952، پتانسیل غشاء بینایی در شرایط نرخ تغییرات عناصر شیمیایی مختلف را توصیف کردند، در اوایل 1960، Fitzhugh براساس دینامیک نورون در روند نوسانی، یک مدل ریاضی برای نوسانگر همراه معرفی کرد. Arndt و همکارانش در سال 1990 مدلی معرفی کردند که هر نورون ورودی را از محرک‌های خاص و از سلول‌های عصبی مجاور دریافت می‌کرد، خروجی سلول‌های عصبی دیگر نیز یک ورودی برای نورون بود. در سال 1992، Rybak و همکارانش مدلی را براساس قشر بینایی خوکچه هندی معرفی کردند که بجز در معادلات، شبیه مدل Eckhorn بود. بعد از آن Johnson و Ritter در سال 1993 شبکه عصبی پالس همراه (PCNN)<sup>1</sup> را معرفی و یک سازوکار جدید با اتصال محدود برای انتقال اطلاعات پیشنهاد دادند. بعد از آن از این شبکه توسط محققین برجسته‌ای چون Johnson، Kuntimad، Ranganath، Padgett و Johnson (1995) و Johnson (1999) برای پردازش تصویر استفاده شد. مدل دیگری توسط Combe، Ducom و Parodi در سال 1996 پیشنهاد شد که در آن تأخیر در اتصالات سیناپسی در نظر گرفته شد. براساس تحقیقات انجام گرفته PCNN توسعه داده شد و مدل قشر متقاطع ICM<sup>2</sup> که مدل ساده‌ای از PCNN بود، توسط Kinser و Ekblad در سال 2004 و Kinser و

\* نویسنده مسئول

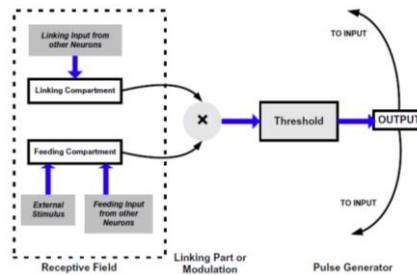
<sup>1</sup> Pulse Coupled Neural Network

<sup>2</sup> Intersecting Cortical Model

Lindblad در سال 2005 معرفی گردید. ICM شبکه‌ای است که در بسیاری از تکنیک‌های پردازش تصویر مانند استخراج ویژگی، شناخت تصویر و قطعه‌بندی تصویر استفاده شده است [1].

## 2- تعریف مدل شبکه عصبی پالس همراه

PCNN شبکه‌ای خود سازمانده می‌باشد که به آموزش احتیاجی ندارد و از فعالیت سلول‌های عصبی پستانداران شبیه‌سازی شده است. ساختار اولیه مدل شبکه عصبی پالس همراه در شکل (1) نشان داده شده است. خروجی شبکه عصبی پالس همراه، خروجی از پالس دودویی تصاویر است که به وسیله تصاویر تحریک شده باشد. Johnson و Padgett در سال 1999 مدل پایه را طراحی و ارتباط با مدل‌های بیولوژیکی را در تحقیقات گسترده‌ای انجام دادند.



شکل 1: ساختار اولیه سلول PCNN [1]

### 2-1- عملکرد PCNN در مدل‌های بیولوژیکی


تعداد نورون‌ها در شبکه پالس همراه با تعداد تصاویر ورودی برابر است. هر پیکسل در تصویر به نورونی منحصر به فرد متصل است و هر نورون با نورون‌های اطراف از طریق یک شعاع به میدان متصل می‌شوند. شبکه عصبی PCNN دارای سه قسمت می‌باشد:

- میدان گیرنده
- ارتباط بین بخشی و یا مدولاسیون
- مولد پالس

میدان گیرنده بخش اولیه برای دریافت سیگنال‌های ورودی از نورون مجاور و منابع خارجی است و دارای دو کانال داخلی شامل تغذیه محدود  $F$  و ارتباط محدود  $L$  است، ورودی‌های ارتباط، زمان پاسخ‌دهی سریع‌تری نسبت به اتصالات محدوده ثابت دارند.

همان‌طور که در شکل (1) مشاهده می‌شود، در شبکه عصبی پالس همراه محدوده ارتباطی و تغذیه در هم ضرب می‌شوند و در نهایت ژنراتور پالس نورون از یک ژنراتور تابع پله و سیگنال ژنراتور آستانه به‌دست می‌آید. نورون‌ها در شبکه توانایی پاسخ به محرک را دارند. این پاسخ به‌عنوان شلیک شناخته می‌شود و زمانی فعال می‌شود که فعالیت‌های داخلی نورون از حد آستانه بالاتر رود. در این حالت خروجی نورون  $Y(U)$  به 1 تغییر می‌کند. مجموعه از حد آستانه شروع می‌شود، تا زمان فعالیت‌های داخلی بعدی نورون کاهش می‌یابد. سپس دوباره با یک تاخیر در تکرار دیگر تغذیه می‌شود. خروجی نورون زمانی که کوچک‌تر از حد آستانه است صفر است. خروجی نورون PCNN به‌صورت یک دنباله زمانی از تعداد در تکرار، به‌دست می‌آید و تصمیم در مورد محتوی تصویر با بررسی خروجی پالس شبکه به‌دست می‌آید [1].

مدل ریاضی شبکه عصبی پالس همراه در شکل (2) قابل مشاهده است. با توجه به مدل ریاضی شبکه عصبی پالس همراه تغذیه ورودی و ارتباط ورودی با سلول‌های عصبی مجاور از طریق وزن‌های سیناپسی  $M$  و  $W$  محاسبه می‌شود. نورون محرک  $S$  است که اطلاعات رنگ پیکسل متناظر با آن را به همراه محرک‌های همسایه در هر دو محدوده مشخص می‌کند.



شکل 2: مدل ریاضی نورون PCNN [2]

با توجه به شکل (2) مدل ریاضی نورون شبکه عصبی پالس همراه، تغذیه محدوده F به صورت معادله (1) و ارتباط محدوده L به صورت معادله (2) مشخص می‌شود.

$$F_{ij}[n] = e^{\alpha_F \delta_n} F_{ij}[n-1] + S_{ij} + V_F \sum_{kl} M_{ijkl} Y_{kl}[n-1] \quad (1)$$

$$L_{ij}[n] = e^{\alpha_L \delta_n} L_{ij}[n-1] + S_{ij} + V_L \sum_{kl} W_{ijkl} Y_{kl}[n-1] \quad (2)$$

در معادله‌های مدل ریاضی نورون شبکه عصبی پالس همراه نمادهای استفاده شده به صورت جدول (1) تعریف شده‌اند.

**جدول 1: نمادهای استفاده شده در مدل ریاضی نورون PCNN**

محدوده تغذیه اولیه نورون (i,j)	$F_{ij}[n]$
خروجی محدوده ارتباط	$L_{ij}[n]$
ورودی محرک از پیکسل تصویر در موقعیت (i,j)	$S_{ij}$
خروجی سلول‌های عصبی از تکرار قبلی	$Y_{kl}$
ضریب ارتباط	$\alpha$
تابع گوسی وزن ثابت با فاصله	$M_{ijkl}$
تابع گوسی وزن ثابت با فاصله	$W_{ijkl}$
پتانسیل ولتاژ ذاتی	$V_F$
پتانسیل ولتاژ ذاتی	$V_L$

حالت‌های مختلف این دو محدوده، از ترکیب وضعیت داخلی نورون محاسبه می‌شود. این حالت‌ها، فعالیت  $U_{ij}[n]$  نامیده می‌شود که از طریق معادله (3) محاسبه می‌شود.

$$U_{ij}[n] = F_{ij}[n][1 + \beta L_{ij}[n]] \quad (3)$$

حالت‌های داخلی نورون شبکه عصبی پالس همراه در معادله (4)، با مقایسه حدآستانه به دست می‌آید، استفاده از  $\theta_{ij}$  برای تولید ضربان‌دار خروجی Y است.

$$Y = \begin{cases} 1; & \text{if } U_{ij}[n] > \theta_{ij}[n] \\ 0; & \text{otherwise} \end{cases} \quad (4)$$

با توجه به معادله (4) وقتی نورون شلیک می‌شود ( $Y > \theta$ )، از حد آستانه به طور قابل توجهی افزایش می‌یابد. این مقدار حد آستانه تا شلیک بعدی افزایش می‌یابد. پویا بودن حد آستانه به صورت معادله (5) قابل تنظیم است. در این معادله  $V_\theta$ ، مقداری ثابت بزرگ‌تر از مقدار  $U_{ij}$  است.

$$\theta_{ij}[n] = e^{\alpha_\theta \delta_n} \theta_{ij}[n-1] + V_\theta Y_{ij}[n] \quad (5)$$

## 2-2- تغییرات در مدل شبکه عصبی پالس همراه

برای کاهش پیچیدگی شبکه PCNN و افزایش سرعت محاسبات، تغییرات خاصی در ساختار شبکه ایجاد شده است. این تغییرات عملکرد کلی شبکه را بهبود داده است. نسخه ساده شده از مدل PCNN، مدل قشر متقاطع<sup>3</sup> است که یک سیستم با استفاده از حداقل دو نوسانگر همراه تابع غیر خطی، با تعداد کمی ارتباط می‌یابد. در این مدل شبکه عصبی پالس همراه تغذیه محدوده F به صورت معادله (6) و ارتباط محدوده L به صورت معادله (7) محاسبه شده است. حد آستانه دینامیک این مدل به صورت معادله (8) تنظیم شده است. در این معادلات S<sub>ij</sub> محرک است و h<sub>ij</sub> آستانه نورون است، Y<sub>ij</sub> خروجی f و g است.

$$F_{ij}[n+1] = fF_{ij}[n] + S_{ij} + W\{Y\}_{ij} \quad (6)$$

$$Y_{ij}[n+1] = \begin{cases} 1; & F_{ij}[n+1] > \theta_{ij} \\ 0; & \text{otherwise} \end{cases} \quad (7)$$

$$\theta_{ij}[n+1] = g\theta_{ij}[n] + hY_{ij}[n+1] \quad (8)$$

## 3- پیاده‌سازی مدل شبکه عصبی پالس همراه

Hikawa ایده‌های مفیدی در رابطه با شبکه‌های عصبی مبتنی بر فرکانس تحریک ارائه کرد [3]. در این مقاله اجرای دیجیتالی برای پیاده‌سازی توجیه شده است. در این رابطه در مورد شبکه‌های چند لایه بحث شده است، این نقطه شروع برای پیاده‌سازی و اجرای بالقوه یک شبکه عصبی پالس همراه کامل بود.

Frankk و همکارانش [4] مدل Eckhorn را با استفاده از ماژول آرایه دروازه‌ای قابل برنامه‌ریزی (FPGA) توصیف کرد. نکات عمده این معماری شتاب‌دهنده‌های دیجیتال به شرح زیر است:

- استفاده از یک نشانی غیرمستقیم (اشاره‌گر) طرح برای مقابله با تعداد اتصالات بزرگ
- لیست عبور الگوریتم منحصربه‌فرد، انتخاب شده برای انطباق آن با واحد FPGA
- شکست تابع عصبی به سه زیرتابع
- شبیه‌سازی زیرتوابع عصبی با VLSI

زیرتوابع عصبی استفاده شده در این پیاده‌سازی عبارتند از: (1) مرحله فروپاشی، (2) انتشار پالس (برورسانی مبتنی بر آکسون به جای دندریت معمول) و (3) سازگاری سیناپسی.

طراحی سیستم تجزیه و تحلیل نهایی نشان داده است VLSI با وجود هزینه قابل توجه، به جهت سرعت قابل قبول بیش از دیگر پیاده‌سازی‌ها مورد توجه است. به طور بالقوه شبیه‌سازی در زمان واقعی از یک مجموعه بزرگ کد سلول‌های عصبی پالس تشکیل شده است. شبیه‌سازی سیستم‌های موتور، شبیه‌سازی تضمینی در فضا و برچسب‌زدن ویژگی‌های بصری، برخی از برنامه‌های کاربردی هستند که از روش کدگذاری پالس بهره برده‌اند.

شبیه‌سازی با معماری CMOS، در یک شبکه پالس همراه پیاده‌سازی شده است. در پژوهشی که در این رابطه انجام شده است [5]، در پرداختن به جزئیات و فیلتر تصاویر از الگوریتم اساسی استفاده شده است. خواص دینامیکی این پیاده‌سازی عبارتند از: (1) آستانه شلیک از خارج قابل تنظیم می‌باشد، (2) برخی از پالس‌های گسترش و تاخیر به دلیل انتشار آکسون است، (3) رفتار موج اتوماتیک مشخصه نابودی پالس متقابل است. معماری و در نتیجه پیاده‌سازی در کوتاه مدت، عملی است که منجر به افزایش قابلیت تقسیم‌بندی تصویر را فراهم کرده است.

Kinser و همکارش [6]، سیستم CNAPS را برای پیاده‌سازی شبکه عصبی پالس همراه معرفی کردند که توانست با مشکلات پردازش تصویر به خوبی برخورد کند و بازده ارزیابی سریعتری نسبت به پیاده‌سازی‌های قبل از خودش داشته باشد.

Reyneri [7] یک مرور کلی و مشروح از پیاده‌سازی سخت‌افزاری موجود در شبکه‌های عصبی و سیستم فازی انجام داده است. در سال 2010، Chen [8] یک مدار آنالوگ برای پیاده‌سازی شبکه عصبی پالس همراه در مجتمع‌سازی مقیاس بسیار بزرگ یا VLSI سخت‌افزاری، با استفاده از نرون MOS معرفی کرد. شبکه عصبی پالس همراه، در معرض تغییرات هندسی بهتر از شبکه‌های دیگر عمل کرده است. پیاده‌سازی این شبکه عصبی در یک معماری موازی VLSI راه امیدوار کننده برای سیستم‌های PCNN زمان واقعی است. در این مقاله [8] مدار معرفی شده قادر به اجرای شبکه عصبی پالس همراه پویا است و مدار قادر به تقلید عملکرد شبکه مانند آستانه پویا و شلیک است، به این معنا که اتصالات عصبی که در ریاضی به عنوان جمع وزن دار سیگنال بیان می‌شود، توسط جمع سیمی از جریان از طریق شبکه مقاومتی اجرا شده است. در این مدار با جریان‌های به‌طور مداوم از طریق مقاومت، افزایش اتلاف توان وجود خواهد داشت که در صورت زیر آستانه بودن، برای اجرای جریان از طریق شبکه‌های عصبی برطرف شده است که این امر سرعت را نسبتاً کاهش خواهد داد. علاوه بر این تراشه‌ای برای ذخیره داده‌ها در این مدار در نظر گرفته شده است.

#### 4- کاربردهای شبکه عصبی پالس همراه

شبکه عصبی پالس همراه در الگوریتم‌های ساختمان داده برای برنامه‌های مختلف مانند قطعه‌بندی، افزایش، همجوشی، استخراج ویژگی، تشخیص لبه، برطرف کردن نوفه، تشخیص الگو، رمزگشایی، نازک شدن تصویر و... استفاده شده است. برنامه‌های کاربردی این شبکه به دو بخش بحث در مورد استفاده در پردازش تصویر و بحث در کاربردهای دیگر مثل طب، پژوهش‌های نظارتی، الگوهای شناخت تقسیم شده است.

##### 1-4-1- قطعه‌بندی تصویر با استفاده از PCNN

قطعه‌بندی تصویر تکنیکی است که گروه پیکسل هر منطقه را تعریف و در نتیجه کل یک شیء را معرفی می‌کند. قطعه‌بندی با استفاده از ویژگی‌های استخراج شده به‌دست می‌آید. بنابراین انتخاب ویژگی خوب در قطعه‌بندی مهم است. نقطه ضعف تمامی روش‌های قطعه‌بندی نیاز به نظارت انسان است که تا حد زیادی روی دقت تاثیرگذار می‌باشد. بهبود عملکرد و کاهش زمان اجرا معیارهایی برای یک سیستم خوب است. در سال 2010 wang و همکارانش [9]، از شبکه عصبی پالس همراه برای جدا کردن یک میوه در پس زمینه‌های پیچیده استفاده کردند. آن‌ها علاوه بر تنظیم ضریب قدرت اتصال تعداد پارامترها را نیز کاهش دادند. Lei و Yang در سال 2010 [10] یک الگوریتم مبتنی بر جستجوی دو طرفه معرفی کردند. این مدل معرفی شده با حل سرعت کم محاسباتی، بهره‌وری کار را افزایش داد. علاوه بر آن، مشکل تصاویر رنگی را در قطعه‌بندی تصاویر رنگی حل کرد. به‌طور مشابه در سال 2010، Hui و Mao [11] با استفاده از بهبود شبکه عصبی پالس همراه قطعه‌بندی چند شیء در یک تصویر را انجام دادند.

در مدل شبکه عصبی پالس همراه ضریب ارتباط و آستانه تحریک اولیه برای سلول عصبی قابل بحث است که در سال 2011، Rava و همکارانش [12] با یک راه حل مناسب، مجموعه‌ای از پارامترهای عمومی و یا پارامترهای محلی سازگار برای کل تصویر تعریف کردند. در رویکرد آن‌ها تصاویر به دو بخش که با هم تداخل دارند و یا تداخل ندارند تقسیم می‌شوند. در نهایت پارامترهای کلی برای هر تصویر محاسبه شده است. مدل CMOS PCNN بر این اساس توسعه داده شده است [13].

شبکه عصبی پالس همراه، از سلول‌های عصبی IAF که نمایشی از دینامیک الکتروشیمیایی سلول‌های عصبی بیولوژیکی طبیعی است الهام گرفته است. از این رو شبکه می‌تواند وزن هر دو نرون را تنظیم، فرکانس را درک و فاز را هماهنگ سازد. علاوه بر آن در دامنه عملکرد شبکه عصبی پالس همراه برای حالت زمان به زمان توسعه یافته است [14]. الگوریتم ایمنی که به کمک پارامترهای شبکه عصبی پالس همراه کار می‌کرد، با در نظر گرفتن آنتروپی تصویر به‌عنوان پایه و اساس ارزیابی تنظیم شده است. پژوهش‌گران نتایج تجربی خود را به همراه روش پیشنهادی برای بهبود عملکرد قطعه بندی تصویر به اثبات رساندند. در سال 2013 روش خوشه‌بندی بیز با شبکه عصبی پالس همراه انجام شده است [2]. دقت قطعه‌بندی به پارامترهای شبکه بستگی دارد، از این رو شبکه عصبی پالس همراه از نظر ورودی و آستانه عصبی پویا ساده شده‌است. با تصاویر مادون قرمز مصنوعی و واقعی شبکه آزمایش شده است و قابلیت ترویج آن نشان داده شده‌است [1].

## 4-2- PCNN در تصویر برداری پزشکی

بسیاری از محققین در حال کار بر روی تکنیک‌های قطعه‌بندی تصویر در زمینه‌های پزشکی با استفاده از شبکه عصبی پالس همراه می‌باشند. این شبکه برای پیش‌پردازش تصویر مناسب است. قطعه‌بندی تصویر در تصاویر پزشکی نقش مهمی در تشخیص بیماری دارد. عکس‌های MRI مغز و تصاویر سونوگرافی عمدتاً در تشخیص کمک‌کننده هستند، با استفاده از شبکه عصبی پالس همراه آموزش دیده در قطعه‌بندی تصاویر کمک زیادی به تصاویر پزشکی می‌شود. شبکه عصبی پالس همراه به صورت پویا، در قطعه‌بندی تصاویر MRI می‌تواند مورد استفاده قرار گیرد. در سال 2009 توسط Chen و همکارش [15] این کار انجام شده است. در تحلیل تصاویر استخراج و پردازش مغز برای تجزیه و تحلیل تصاویر و تشخیص بیماری بسیار مهم است. شبکه عصبی پالس همراه توسعه یافته برای استخراج مغز سه بعدی برای کمک به عمل جراحی معرفی شد [16]. در این مقاله از کل تصویر سه بعدی برای استخراج مغز استفاده شده است. همچنین نشان داده شده است که شبکه عصبی پالس همراه سه بعدی در مقایسه با شبکه عصبی پالس همراه دو بعدی برای استخراج مغز موش بهتر عمل می‌کند. به طور مشابه در برداشت خودکار مغز از تصاویر MRI در سطح حداقل صفر از وزن دهی T2 استفاده شده است [17]. شبکه‌های عصبی پالس همراه در قطعه‌بندی‌های دیگر مغز با مدل حداکثر انتظار آماری<sup>4</sup> یکپارچه شده است. محققین در سال 2010 به قطعه‌بندی تصویر به طور کامل با تنظیم خوب پارامترهای شبکه عصبی پالس همراه دست یافتند [18]. این کار تحقیقی شامل EM-PCNN غیر انطباقی بوده است و با روش فازی C-Means<sup>5</sup> الگوریتم قطعه‌بندی تصویر مغز را اصلاح کرده است. یک تکنیک پایه روی آنتروپی Tsallis با توسعه شبکه عصبی پالس همراه توسط Zhanfang [19] برای قطعه‌بندی تصاویر پزشکی به صورت خودکار انجام شد که می‌توانست تصاویر دو بعدی با آنتروپی Tsallis را قطعه‌بندی کند. در این قطعه‌بندی از تصاویر گرفته شده با امواج فرا صوت مغز استفاده شده است. در مقاله [20] نویسندگان به دنبال کمک گرفتن از شبکه عصبی پالس همراه در تشخیص مرز پروستات در تصاویر سونوگرافی بوده‌اند. در این مدل مقادیر شدت تصاویر اصلی با استفاده از شبکه عصبی پالس همراه و فیلتر میانه تنظیم شده است و پس از آن الگوریتم قطعه‌بندی برای تشخیص مرز به کار گرفته شده است. مهمترین کار انجام شده در این زمینه ترکیب شلیک دینامیک شبکه پالس همراه با روش Otsu دو بعدی است [21]. با یک روش جدید توسط Chen در سال 2009 شبکه عصبی پالس همراه توسعه داده شد [22]. در این مقاله بر روی تقسیم‌بندی شبکه عصبی خونی کار شده است و عملکرد خوبی را برای وضوح تصاویر نرمال و کم شبکه نشان داده است. تصاویر شبکه توسط شبکه عصبی پالس همراه پیش‌پردازش شده‌اند. Otsu، یک روش غیر پارامتری بسیار محبوب در قطعه‌بندی تصاویر پزشکی است. آستانه این روش تصاویر خاکستری است اما محاسبات آن بسیار پیچیده می‌باشد. برای تشخیص سرطان می‌توان با قطعه‌بندی، غدد طبیعی و بدخیم را شناسایی کرد. Wolfer در سال 2012 از شبکه عصبی پالس همراه به همراه چند اپراتور مورفولوژیکی در پردازش ماموگرام استفاده کرد [23]. او از شبکه عصبی پالس همراه برای تشخیص زود هنگام سرطان سینه استفاده کرد. از این شبکه برای قطعه‌بندی اسلایدهای بافت شناسی نیز می‌توان استفاده کرد. Hage و Hamade در سال 2013 [24] این کار را انجام دادند و یافته‌های خود را با روش سنتی ارزیابی نمودند و برتری شبکه عصبی پالس همراه را در این زمینه تایید کردند.

## 4-3- همجوشی تصویر با استفاده از PCNN

همجوشی تصویر یکی از تکنیک‌های بسیار مهم در پردازش تصویر می‌باشد. شبکه عصبی پالس همراه اولیه در استفاده از تکنیک‌های ترکیب دچار کاستی‌هایی است. در سال 2008، Ma و Wang [25] یک مدل شبکه عصبی پالس همراه چند کاناله برای همجوشی تصاویر پزشکی پیشنهاد کردند. m-PCNN پیشنهاد شده می‌توانست با تصاویر چند رسانه‌ای پزشکی کار کند. از چهار جفت تصاویر پزشکی برای آزمایش کارایی m-PCNN در برابر روش‌های دیگر مثل وضوح هرمی استفاده شده است. هرم FSD، هرم شیب و هرم لاپلاس، الگوریتم‌های همجوشی تصویر در حوزه شبکه عصبی پالس همراه هستند [26]. قدرت و دامنه ارتباط به وسیله ضریب پایین فرکانسی ویژگی‌های عمومی تصویر تعیین می‌شود. هنگامی که تصویر ورودی یک تصویر MRI باشد، زمان اجرای این الگوریتم کم است. Bhattacharya و همکارانش [27] در یک الگوریتم از همجوشی چند قطعه استفاده کردند، آن‌ها برای بهبود همجوشی از روش قطعه‌بندی تصویر از مدل فازی C-Mean و مارکوف تصادفی قبل از اقدام به همجوشی تصویر استفاده کردند. در حوزه curvelet، تصاویر اولیه با استفاده از LSWT و یک کانال جدید دوگانه شبکه عصبی پالس همراه توسعه داده شده، تجزیه شده‌اند. Haung و

<sup>4</sup> EM

<sup>5</sup> BCFCM

Jing [28] در سال 2007، بر روی الگوریتم ترکیب تصویر کار کردند. برای اندازه‌گیری وضوح تصویر، از بلوک‌های انرژی لاپلاسیان تصویر استفاده کردند و برای آموزش از شبکه عصبی پالس همراه استفاده شد. در سال 2012 wang و همکارانش با برخی آزمایش‌ها که استفاده از موجک بلند برای اجسام غیرقابل تفکیک و شبکه عصبی پالس همراه در یک زمان انجام دادند، کیفیت بهتر همجوشی بصری به دست آمده بود [9]. در سال 2013 Cheng و همکارانش یک ماتریس برش برای تجزیه تصاویر در چند جهت معرفی کردند که در آن از ویژگی‌های شیب استخراج و از ضریب فرکانس بالای شبکه عصبی پالس همراه استفاده شد. در این پژوهش تجزیه مقیاس توسط چند موجک انجام شده است [29].

#### 4-4- استخراج ویژگی و تشخیص لبه با PCNN

در سال 2007، Gu شبکه عصبی ULPCNN را برای تشخیص لبه و استخراج ویژگی معرفی کرد که در این مقاله [30] از اطلاعات رنگ و ساختار هندسی توزیع رنگ برای استخراج ویژگی‌های تصویر استفاده شد. این شبکه عصبی به دلیل زمان اجرای مناسب الگوریتم به راحتی در سخت‌افزارها قابل استفاده است. در سال 2009 Wang و Liu [31] شبکه عصبی AULPCNN را برای اجرای آسان، شناخت دقیق‌تر و مقابله با نوفه معرفی کردند. در سال 2010 Shi و Hu [32] یک روش جدید برای تشخیص لبه با استفاده از ارتباط ناهمسان‌گرد<sup>6</sup> سازوکار پیشنهاد کردند. نویسندگان این مقاله [32] ثابت کردند که شبکه PCNNAI کارآمد و قابل کنترل است. نتایج زمانی تشخیص لبه در مقایسه با روش‌های کلاسیک دقیق‌تر می‌باشد. در سال 2013 Xian-Wen و Jie-Sheng یک شبکه با توجه به اهمیت حیاتی انتخاب پارامترها معرفی کردند که جستجوی تشخیص لبه‌های تصویر به صورت خودکار مورد استفاده قرار گرفت [33].

#### 4-5- تحلیل قطعه‌بندی بافت تصویر با استفاده از PCNN

قطعه‌بندی بافت در تجزیه و تحلیل تصویر دشوار است. شبکه عصبی پالس همراه با استفاده از سری‌های زمانی ویژگی‌ها و الگوریتم FCM<sup>7</sup> بافت تصویر را قطعه‌بندی می‌کند. در مقاله [34] نویسندگان روشی را برای ارزیابی نوع و حساسیت بافت مجاور بر اساس روش‌نمایی معرفی کرده‌اند. در این پژوهش از شبکه عصبی پالس همراه برای شناسایی نقص‌های بافت در زمان دید واقعی استفاده شده است. شدت نور مختلف بین زمینه دارای نقص و زمینه بدون نقص برای شلیک نورون تقسیم‌بندی شده است. در سال 2010 Jia [35] ساختار تکرار شبکه عصبی پالس همراه را توسط حداقل آنروپی متقابل برای قطعه‌بندی بافت تصویر به کار گرفت. در سال 2010 Liu و همکارانش [36] بافت پس‌زمینه و ویژگی‌های بافت تصویر را برای قطعه‌بندی در نظر گرفتند. آن‌ها یک پارامتر جدید برای مقایسه یک تصویر ناقص و یک تصویر بدون نقص معرفی کردند. در این پژوهش یک بردار پشتیبان برای پردازش تصویر به کار گرفته شد.

#### 4-6- از بین بردن نوفه با استفاده از PCNN

کاهش نوفه یکی از کارهای پیش‌پردازش تصویر است. شبکه عصبی پالس همراه یک پیش‌پردازنده خوب می‌باشد. این شبکه برای صاف کردن کامل یک تصویر استفاده می‌شود. مزیت این روش حذف پیکسل نوفه بدون حذف پیکسل‌های دیگر است. با این روش جزئیات دیگر تصویر و اطلاعات لبه‌ها حفظ نخواهد شد. در مقاله [37] برای حذف نوفه نمک - فلفل، از شبکه عصبی پالس همراه استفاده شده است که بدون اخلاص در دیگر پیکسل‌ها، پیکسل‌های نوفه را حذف کرده است و به این ترتیب جزئیات تصویر و اطلاعات لبه حفظ شده‌اند. این شبکه از فیلتر میانه و وینر بهتر جواب داده است.

#### 4-7- تکنیک مدار بسته با PCNN

استفاده در وسایل نقلیه هوایی بدون سرنشین، ایمنی سازمان و مراکز تحقیقاتی، نیروگاه‌ها و... زیرساخت الکتریکی شبکه عصبی پالس همراه است، در سال 2010 Zhang و همکارانش [38] برای از بین بردن نوفه پس‌زمینه تصاویر هوایی از این شبکه استفاده کردند. در سال 2013 Tolba و همکارش [39] با تطبیق گراف با استفاده از شبکه عصبی پالس همراه نرخ شناخت را تا هفتاد درصد رساندند. علاوه بر آن تشخیص تصویر امضا و تصاویر ماهواره‌ای نیز به این شبکه قابل تشخیص هستند.

#### 5- شبکه عصبی پالس همراه توسعه یافته

در این بخش بهبود شبکه در جهت استفاده در پردازش تصویر بررسی شده است.

<sup>6</sup> Anisotropic

<sup>7</sup> Fuzzy C-Means


## 5-1- مدل توسعه یافته

شبکه عصبی پالس همراه دو بعدی با  $n \times m$  نورون معرفی می‌شود. در جدول (2) نمادهای استفاده شده در مدل شبکه عصبی پالس همراه دو بعدی تعریف شده‌اند.

جدول 2: نمادهای استفاده شده در مدل PCNN دوبعدی

نورون $(m, n)$	$N_{m \times n}$
سیگنال پیکسل	$X_{m \times n}$
پالس سیگنال	$Y_{m \times n}$
آستانه $N_{m \times n}$	$\Theta_{m \times n}$
مجموعه ارتباطی نورون $N_{m \times n}$	$L(N_{m \times n})$
وزن ارتباط بین $N_{i,j}$ و $N_{m \times n}$ در مجموعه $L$	$W_{i,j}$
فعالیت داخلی کل نورون $N_{m \times n}$	$U_{m \times n}$

همان‌طور که در شکل (3) نشان داده شده است، نورون همیشه ترکیبی از سیگنال پیکسل و سیگنال‌های پالس را دریافت می‌کند. مجموع وزنی تمام ورودی‌های مرتبط در قسمت مدوله شده برای تولید فعالیت داخلی کل نورون استفاده می‌شود و پس از آن فعالیت کل با آستانه پالس‌های مولد پالس به منظور تعیین این‌که آیا یک پالس باید تولید شود یا خروجی مقایسه شده است.



شکل 3: مدل بهبود یافته PCNN [40]

شبکه‌های تکرار شونده برای بهبود اتصال به شبکه عصبی پالس همراه موجود وارد می‌شوند. با فرض وجود  $t$  ( $0 \leq t \leq +\infty$ )، شبکه به عنوان دنباله‌ای از تکرار برای آئین نورون دینامیک در حال اجرا، حالت فعالیت نورون با استفاده از معادله (9) و خروجی با معادله (10) محاسبه می‌شود.

$$U_{m \times n}(t) = X_{m \times n}(t) \times [1 + \beta \sum_{i=1}^i \sum_{j=1}^j W_{i,j} \Phi_{i,j}(t)] \quad (9)$$

$$Y_{m \times n}(t) = F(U_{m \times n}(t) - \Theta_{m \times n}(t)) \quad (10)$$

قدرت اتصال  $\beta > 0$ ، قابل تنظیم است. نورون  $N_{i,j} \in L(N_{m \times n})$  تعریف می‌شود و در معادله (11) کل اتصالات ورودی به نورون  $N_{i,j}$  را نشان می‌دهد. وزن‌های  $W_{i,j}$  به صورت معادله (12) تعریف شده است.

$$\Phi_{i,j}(t) = X_{i,j}^Y e^{Y_{i,j}} \quad (11)$$

$$W_{i,j} = \begin{cases} e^{1-d_{i,j}}, & d_{i,j} > 0 \\ 1, & d_{i,j} = 0 \end{cases} \quad (12)$$

$d_{i,j}$  نشان‌دهنده فاصله اتصال از نورون  $N_{m \times n}$  به نورون  $N_{i,j}$  است. فاصله یک سلول به خودش صفر در نظر گرفته می‌شود. در نرم‌افزارهای دنیای واقعی، اتصالات مختلف مجموعه باعث پویایی نورون‌های مختلف می‌شود در نتیجه ارتباط بین نورون‌های مجموعه



L یک مشکل بسیار مهم است. معمولا ارتباط مجموعه نورون‌های مربع  $3 \times 3$  یا  $5 \times 5$  انتخاب می‌شوند، انتخاب مجموعه بیش از حد کوچک مثل  $1 \times 1$  یا بیش از حد بزرگ مثل  $21 \times 21$  ممکن است عملکرد شبکه عصبی پالس همراه را کاهش دهد. در نرم‌افزار پردازش تصویر لازم نیست ارتباط نورون‌ها یک میدان مربعی باشد. ممکن است به صورت  $\times$  و یا  $+$  باشند یا یک مجموعه نامربع مثل  $5 \times 3$  باشد. انتخاب طرح مجموعه نورون‌ها عملا توسط متخصص تعیین می‌شود. در مقاله [40] از ماتریس مربعی دو بعدی P برای ارتباط نورون‌ها استفاده شده است. در این مدل بهبود یافته آستانه به صورت معادله (13) بیان می‌شود.

$$\Theta_{mn}(t) = \varphi(N_{11}, N_{12}, \dots, N_{ij}) \quad (13)$$

بعد از شلیک نورون یک سیگنال پالس به خروجی می‌رود، وضعیت مولد پالس از معادله (14) محاسبه می‌شود.

$$F(U_{mn} - \Theta_{mn}) = \begin{cases} 1; & \text{if } U_{mn} \geq \Theta_{mn} \\ 0; & \text{else} \end{cases} \quad (14)$$

### 5-2- بهبود PCNN در برنامه‌ریزی مسیر

در مقاله [41] یک پالس موجک خودکار که توسط شبکه عصبی GAPCNN هدایت می‌شود برای دستگاه خودکار موبایل برنامه‌ریزی شده است تا یک مسیر بهینه را برای رسیدن به مقصد پیدا کند. الگوریتم‌های مبتنی بر نمونه‌گیری و احتمالاتی راه نقشه دارای محدودیت‌هایی در پیاده‌سازی می‌باشد. اخیرا نیز الگوریتم ژنتیک و روش فازی برای برنامه‌ریزی مسیر ارائه شده است در این رابطه از شبکه‌های عصبی برای پیدا کردن کوتاه‌ترین مسیر در برنامه‌ریزی راه استفاده می‌شود. یکی از روش‌های حل مشکلات کوتاه‌ترین مسیر استفاده از شبکه عصبی پالس همراه می‌باشد. استفاده از این روش نیاز به تعداد زیادی از سلول‌های عصبی برای پیدا کردن راه دارد که در نتیجه محاسبات پیچیده و زمان‌بر است [42]. برای بهبود، روش PCNN مدل اصلاح شده آن MPCNN توسط Hong و همکارش [43] معرفی شد.

#### 5-2-1 MPCNN برنامه‌ریزی مسیر

مجموعه همسایه‌های یک نورون خاص که به آن به طور مستقیم متصل هستند، در یک مجموعه به نام  $N^s$  قرار داده می‌شود. فاصله اقلیدسی آن‌ها از هم یک در نظر گرفته می‌شود. به همین ترتیب همسایه‌های مورب در مجموعه  $N^d$  در نظر گرفته می‌شود و فاصله اقلیدسی آن‌ها از هم  $\sqrt{2}$  است. برای همسایه‌های نورون  $i$  وزن‌های معادله (15) در نظر گرفته می‌شود.

$$w_{ij} = \begin{cases} 1; & \text{if } j \in N^s \\ \sqrt{2}; & \text{if } j \in N^d \end{cases} \quad (15)$$

هر نورون فقط یک بار در طول عمر خود شلیک می‌کند. خروجی نورون  $i$  در زمان  $t$  برابر با معادله (16) است.

$$Y_i(t) = \begin{cases} 0 & \text{for } T - \varepsilon \leq t < T \\ 1 & \text{for } t = T \\ 0 & \text{for } T < t \leq T + \varepsilon \end{cases} \quad (16)$$

$\varepsilon$  می‌تواند هر مقدار از زمان باشد و  $T = t_{fire}^i$  زمانی است که نورون  $i$  شلیک می‌کند. نورون  $i$  فقط زمانی شلیک می‌شود که نورون همسایه آن  $j$ ، شلیک شده باشد. مجموعه نورون‌های فرزند  $i$  بعد از آن شلیک خواهند شد. نورون  $j$  پدر موقت  $N_i^{p*}$  نامیده می‌شود و زمان شلیک آن  $t_{fire}^{N_i^{p*}}$  است. اگر نورون همسایه دیگر قبل از  $i$  شلیک شود آن نورون پدر موقت جدید  $i$  خواهد شد. زمانی که  $i$  شلیک شد  $t_{fire}^i$  نورون پدر موقت خود را به عنوان نورون پدرش ثبت می‌کند. انرژی هنگام شلیک نورون  $U(t)$  به عنوان فعالیت داخلی شناخته می‌شود. یک نورون فعال است که نورون پدرش قبل از خودش فعال باشد و تکرار فعالیت پدرش در زمان فعالیت خودش صفر باشد و به صورت معادله (17) نشان داده می‌شود.

$$\begin{cases} \frac{dU_i(t)}{dt} = F_i + CL_i; \text{for } t > t^{N_i^p} \\ U_i(t) = 0; \text{for } t \leq t^{N_i^p} \end{cases} \quad (17)$$

در معادله (17)، C ثابت است و  $F_i(t)$  و  $L_i(t)$  پیوند نورون‌های ورودی است. در مدل ریاضی این شبکه تغذیه محدوده F به صورت معادله (19) و ارتباط محدوده L به صورت معادله (18) محاسبه شده است.

$$L_i(t) = f(Y_{N^1}, \dots, Y_{N^k}, t) = \begin{cases} 0; \text{if } t < t^{N_i^p} \\ 1; \text{else} \end{cases} \quad (18)$$

$$F_i(t) = -g(w_{ir, 1}, \dots, w_{ir, k}, t) U_i(t) \quad (19)$$

$$g(w_{ir, 1}, \dots, w_{ir, k}, t) = \begin{cases} 0; \text{if } t < t^{N_i^p} \\ \mu(w_{ij}); \text{if } t > t^{N_i^p} \end{cases} \quad (20)$$

$$\mu(w_{ij}) = \frac{B}{w_{ij}} = \begin{cases} B; \text{if } j \in N^s \\ \frac{B}{\sqrt{2}}; \text{if } j \in N^d \end{cases} \quad (21)$$

در این معادلات B ثابت مثبت است و با توجه به گر پد همسایه مستقیم است یا مورب تابع فعالیت  $U_i(t)$  افزایش می‌یابد. انرژی نورون به طور پیوسته با سطح آستانه مقایسه می‌شود، سطح آستانه برای نورون i به صورت معادله (22) نشان داده شده است.

$$\theta_i(t) = \begin{cases} \theta_{init}; \text{for } t < t^{N_i^p} \\ \theta_{ij}; \text{for } t^{N_i^p} \leq t < t_{fire}^i \\ \theta_f; \text{for } t > t_{fire}^i \end{cases} \quad (22)$$

$\theta_{init}$  و  $\theta_f$  مقادیری ثابت هستند،  $\theta_f$  مقادیر بزرگی است به سبب آن که نورون دوباره شلیک نشود و معادله (23) میزان  $\theta_{ij}$  را محاسبه می‌کند.

$$\theta_{ij} = \begin{cases} \theta_s; \text{if } j \in N^s \\ \theta_d; \text{if } j \in N^d \end{cases} \quad (23)$$

z پدر موقت i می‌باشد،  $\theta_s$  و  $\theta_d$  مقدار مثبت ثابت که مقدار آستانه را برای همسایه‌های ثابت و مورب بیان می‌کند. خروجی MPCNN به صورت معادله (24) محاسبه می‌شود.

$$Y_i(t) = \text{Step}(U_i(t) - \theta_i(t)) = \begin{cases} 1; \text{if } U_i(t) \geq \theta_i \\ 0; \text{else} \end{cases} \quad (24)$$

## 2-2-5- GAPCNN مدل

مدل GAPCNN برای نورون i در شکل (4) نشان داده شده است. این مدل دو تفاوت عمده با مدل MPCNN دارد. نخست تابع آستانه مدل است. در مدل MPCNN تنها تابعی از زمان است در حالی که در این مدل تابعی از زمان و مسافت است و به صورت معادله (25) نشان داده شده است.

$$\theta_i(t, \lambda) = \begin{cases} \theta_{init}; & \text{for } t < t^{N^{p^*}_i} \\ \theta_{ij} - \lambda_i; & \text{for } t^{N^{p^*}_i} \leq t < t_{fire}^i \\ \theta_f; & \text{for } t > t_{fire}^i \end{cases} \quad (25)$$

در معادله (25)  $\lambda$  به صورت معادله (26) تعریف می‌شود.

$$\lambda_i = a \left( 1 - \frac{D_{target}}{D_{max}} \right) \quad (26)$$

$D_{target}$  فاصله اقلیدسی از نورون هدف است،  $D_{max}$  ثابت است، فاصله بین دورترین سلول‌های عصبی از هم در شبکه است. تفاوت دوم این دو مدل از هم موجک اتوماتیک است. در این مدل با استفاده از یک تغییر زاویه در معادله دیفرانسیل اصلی، فعالیت‌های داخلی نورون به دست می‌آید. مقدار  $U_i(t)$  به صورت معادله (27) به دست می‌آید. در مدل ریاضی این شبکه تغذیه محدود  $F$  به صورت معادله (29) و ارتباط محدود  $L$  به صورت معادله (28) محاسبه شده است.

$$\begin{cases} \frac{dU_i(t)}{dt} = F_i + CL_i; & \text{for } t \geq t^{N^{p^*}_i} \\ U(t^{N^{p^*}_i}) = 0 \end{cases} \quad (27)$$

$$L_i(t) = f(Y_{N^1}, \dots, Y_{N^k}, t) = \begin{cases} 0; & \text{if } t < t^{N^{p^*}_i} \\ 1; & \text{else} \end{cases} \quad (28)$$


$$F_i(t) = -g(w_{iN^1}, \dots, w_{iN^1}, \psi, t) U_i(t) \quad (29)$$

$$g(w_{iN^1}, \dots, w_{iN^1}, \psi, t) = \begin{cases} 0; & \text{if } t < t^{N^{p^*}_i} \\ \mu(w_{ij}) + \psi_i; & \text{if } t > t^{N^{p^*}_i} \end{cases} \quad (30)$$

$$\begin{aligned} \psi_i &= K(\alpha - \beta_i) \\ K &= p\delta \end{aligned} \quad (31)$$

$\alpha$  زاویه شروع از هدف می‌باشد و با فرض این که سیستم به هدف هماهنگ است محاسبه شده است. جهت‌گیری در کل محاسبات باید یکسان در نظر گرفته شود،  $p$  ثابت تناسب است،  $\delta$  تفاوت در نرخ شلیک‌های زمان  $t$  و  $t+1$  است. کاهش در میزان شلیک نشان می‌دهد در مقابل موج انسداد وجود دارد و در نتیجه  $k$  برای باز کردن راه موجک کاهش پیدا می‌کند و این کار به صورت محلی رخ می‌دهد. خروجی مدل با استفاده از معادله (32) محاسبه می‌شود.

$$Y_i(t) = \text{Step}(U_i(t) - \theta_i(t, \lambda)) = \begin{cases} 1; & \text{if } U_i(t) \geq \theta_i \\ 0; & \text{else} \end{cases} \quad (32)$$



شکل 4: مدل GAPCNN [41]

## 6- PCNN بهبود یافته برای قطعه‌بندی تصاویر

از شبکه عصبی پالس همراه برای قطعه‌بندی تصاویر استفاده شده است در این بخش از مقاله به بهبودهای این شبکه در مسئله قطعه‌بندی تصاویر پرداخته شده است.

### 6-1- استفاده از PCNN ساده در قطعه‌بندی تکرار شونده

برخلاف شبکه‌های عصبی دیگر این مدل [2] برای قطعه‌بندی، نیاز به تمرینات سنگین ندارد و به طور کلی با تکرار گسسته ورودی و خروجی نورون این کار را انجام می‌دهند. در مدل ریاضی تکرار شونده این شبکه تغذیه محدوده  $F$  به صورت معادله (33) و ارتباط محدوده  $L$  به صورت معادله (34) محاسبه شده است. حالت فعالیت نورون با استفاده از معادله (35)، خروجی با معادله (36) و آستانه دینامیک عصبی نورون به وسیله معادله (37) محاسبه می‌شود.

$$F_x(n) = e^{-\alpha F} F_x(n-1) + V_F \sum_y M_{x,y} Y_y(n-1) + I_x \quad (33)$$

$$L_x(n) = e^{-\alpha L} L_x(n-1) + V_L \sum_y M_{x,y} Y_y(n-1) \quad (34)$$

$$U_x(n) = F_x(n) \cdot [1 + \beta L_x(n)] \quad (35)$$

$$Y_x(n) = \begin{cases} 1, & U_x(n) > E_x(n-1) \\ 0, & \text{otherwise} \end{cases} \quad (36)$$

$$E_x(n) = e^{\alpha E} E_x(n-1) + V_E Y_x(n) \quad (37)$$

در معادله‌های مدل ریاضی نورون شبکه عصبی پالس همراه قطعه‌بندی تصویر نمادهای استفاده شده به صورت جدول (2) تعریف شده است.

جدول 2: نمادهای استفاده شده در مدل ریاضی نورون PCNN قطعه‌بندی تصویر


متغیرهای مکانی مستقل برای نشان دادن عرض یک پیکسل	X
متغیرهای مکانی مستقل برای نشان دادن	Y

طول یک پیکسل	
وزن‌های سیناپسی پیوند سلول‌های عصبی براساس نزدیکی مکانی	$M_{x,y}$
وزن‌های سیناپسی پیوند سلول‌های عصبی براساس نزدیکی مکانی	$W_{x,y}$
عامل کاهش تعیین وضعیت داخلی دو ورودی	$\alpha_F$
عامل کاهش تعیین وضعیت داخلی دو ورودی	$\alpha_L$
اندازه تغییرات مقیاس محرک‌های محلی	$V_F$
اندازه تغییرات مقیاس محرک‌های محلی	$V_L$
ضریب قدرت ترکیبی	$\beta$
آستانه دینامیک عصبی	$E$
کنترل تغییرات آستانه دینامیک	$\alpha_E$
کنترل تغییرات آستانه دینامیک	$V_E$

هر یک از متغیرهای استفاده شده در معادلات ریاضی شبکه عصبی پالس همراه را برای تنظیم رفتار نورون، می‌توان تغییر داد. مقدار بزرگ  $\beta$  ممکن است سلول‌های عصبی مجاور را به اشتباه کم ارزش کنند یا مقدار کوچک آن سلول‌های مجاور را به سوی روشنی بالا هدایت کند. این پارامتر کلیدی برای حفظ ویژگی‌های شبکه عصبی پالس همراه است.

## 6-2- مدل ساده PCNN برای قطعه‌بندی تصویر

مدل ساده SPCNN برای قطعه‌بندی تصویر به صورت شکل (5) ارائه شده است، دو ورودی F و L قابل تغییر است. در مدل ریاضی تکرار شونده این شبکه تغذیه محدوده F به صورت معادله (38) و ارتباط محدوده L به صورت معادله (39) محاسبه شده است.



شکل 5: ساختار پیشنهادی مدل ساده PCNN [2]

$$F_x(n) = \sum_y I_y M_{x,y} \quad (38)$$

$$L_x(n) = \sum_y W_{x,y} Y_y(n-1) \quad (39)$$

در معادله (39) وزن ارتباط بین سلول‌های عصبی مجاور است و برای تعیین آن می‌توان از معکوس فاصله اقلیدسی بین سلول‌های عصبی معادله (40) استفاده کرد.

$$w_{x,y} = \begin{cases} 0, & x = y \\ 1/\|x - y\|_2, & x \neq y \end{cases} \quad (40)$$

و  $M_{x,y}$  در معادله (38) با همسایه سلول‌های عصبی ارتباط دارد و در عمل هسته گاوسی نامتقارن است که به صورت معادله (41) تعریف می‌شود.

$$M_{x,y} = C_\sigma \exp(\|x - y\|^2 / 2\sigma^2) \quad (41)$$

در معادله (41)،  $C_\sigma$  ثابت نرمال است و  $\sigma$  کنترل صافی از هشت همسایه است و اغلب به مقدار مساوی با یک بیان می‌شود. علاوه بر این برای رسیدن به کارایی بالا برای قطعه‌بندی تصویر در این شبکه عصبی پالس همراه دو کار دیگر نیز باید انجام شود:

1- مقطع آستانه  $E$ ، با کنترل به طور معناداری بیشتر از شلیک نورون‌های پس‌زمینه، تحت شرایط خاص نورونی که یک بار شلیک کرده است را نگه دارد.

2- برای بیشتر نگه داشتن نبض همزمان از یک راهبرد درشت به ریز برای گرفتن سلول‌های عصبی شیء با نزدیکی مکانی استفاده شود.

برخلاف مدل ساده شبکه عصبی پالس همراه، ایده اصلی این روش، یک خروجی پالس  $Y$  است که در آن سلول‌های عصبی دارای بالاترین ارزش تغذیه ورودی و یک مقدار ضریب ارتباط برای تشویق سلول‌های عصبی با نزدیکی مکانی برای شروع اخراج می‌باشد. مدل انطباقی بروزرسانی آستانه و همچنین ضریب اتصال به زور سلول‌های عصبی شیء به دقت در هر تکرار اخراج می‌شود و هنگامی که خروجی پالس دیگر تغییر نمی‌کند تکرار متوقف می‌شود.

### 1-2-6- آستانه عصبی $E$

در مقاله [2] یک آستانه مرتبط با هیستوگرام تصویر و خروجی پالس تعریف شده است. اگر خروجی پالس  $Y(n-1)$  در نظر گرفته شود، کل تصویر  $\Omega$  باید به دو ناحیه جدا از هم (42) و (43) تفکیک شده باشد، برای نقطه  $x$  مناطق پس‌زمینه و اشیای داخل تصویر آستانه به صورت معادله (44) تعریف می‌شود.

$$\Omega_1 = \{x \mid Y_x(n-1) = 0\} \quad (42)$$

$$\Omega_2 = \{x \mid Y_x(n-1) = 1\} \quad (43)$$

$$E_x(n) = V_1(n) \cdot H_\varepsilon(V_1(n) - F_x) + V_2(n) \cdot H_\varepsilon(V_2(n) - F_x) \quad (44)$$

در معادله (44)،  $n$  شاخص تکرار است،  $V_1$  و  $V_2$  دامنه و  $H_\varepsilon$  تقریب منظمی است که به صورت معادله (45) تعریف می‌شود.


$$H_\varepsilon(z) = 1/2 \times (1 + 2/\pi \times \arctan(z/\varepsilon)), \varepsilon > 0 \quad (45)$$

در معادله (45)، مقدار  $\varepsilon$  را می‌توان ثابت در نظر گرفت. این حد آستانه می‌تواند تصویر ورودی را به سه سطح از هم جدا کند:  $[0, V_1(n)]$ ،  $[V_1(n), V_2(n)]$  و  $[V_2(n), 255]$ ، همان‌طور که در شکل (6) نشان داده شده است، تصویر شامل سه ناحیه پس‌زمینه، ناحیه مختلط و ناحیه شیء است. هر سطح دارای یک آستانه عصبی است که با ارزش‌های  $V_1$  و  $V_2$  از طریق تکرار تعیین می‌شود. در این مدل انتخاب  $V_1$  و  $V_2$  تا زمانی که شرایط زیر برقرار باشد انعطاف‌پذیر است:

- در بازه  $[0, V_1(n)]$ ، ارزش  $V_2 + V_1$  باید به اندازه کافی بزرگ باشد تا اطمینان حاصل شود نورون اخراج شده نورون

پس‌زمینه نیست.

- در فاصله  $[V1(n), V2(n)]$ ، با زیاد شدن مقدار  $V2$ ، فعالیت داخلی نورون‌های شیء، آستانه عصبی افزایش یابد و خروجی پالس تولید شود.
- در فاصله  $[V2(n), 255]$ ، به دلیل آن که نورون متعلق به شیء می‌باشد باید شلیک شود. در واقع برای شلیک نشدن نورون متعلق به پس‌زمینه می‌باشد.



شکل 6: طرح هیستوگرام تصویر [2]

مقدار  $\beta$  بر اساس نزدیکی مکانی برای تولید یک پالس است هنگامی که فعالیت‌های داخلی نورون بیش از مقدار  $V2(n)$  رسیده باشد. در این مقاله [2] برای جبران کردن مقدار آستانه، مرکز خوشه از پس‌زمینه انتخاب شده است. مرکز خوشه  $m_c(n)$  ( $n=1,2$ ) با توجه به وضعیت خروجی پالس قبلی مطابق با معادله (46) محاسبه شده است.

$$m_c(n) = \sum_{x \in \Omega_c} F_x / \sum_{x \in \Omega_c} I, c = 1, 2 \quad (46)$$

### 2-2-6- ضریب ارتباط $\beta$

ضریب ارتباط اثر قابل توجهی بر روی فعالیت‌های داخلی نورون‌ها دارد. تعیین مقدار بهینه برای قطعه‌بندی طیف گسترده تصاویر مشکل است. مقدار این پارامتر توسط آزمون و خطا تنظیم می‌شود و این کار مانع از قطعه‌بندی تصویر به صورت خودکار می‌باشد که این مقاله [2] یک راهبردی از درشت به ریز برای مقابله با این مشکل معرفی شده است. در این الگوریتم سلول‌های عصبی شیء با نزدیکی مکانی، شلیک می‌شوند.

در طبقه‌بندی درشت، منطقه شلیک به صورت معادله (47) در نظر گرفته می‌شود. در این طبقه‌بندی مجموعه‌ای از سلول‌های عصبی با نزدیکی مکانی و شدت روشنایی مشابه، می‌توانند با  $\Omega_2$  نشان داده شوند. آستانه این طبقه‌بندی به صورت معادله (48) و ضریب ارتباط به صورت معادله (49) محاسبه می‌شوند.

$$\Omega_2 = \{x | Y_x(n-1) = 1\} \quad (47)$$

$$\min_{\beta} \Phi = \sum_x [(1 + \beta L_x(n)) \cdot F_x - V_2(n)]^2, x \in \Omega_2 \quad (48)$$

$$\beta = \frac{\sum_x (I_x - V_2(n)) F_x L_x(n)}{\sum_x F_x^2 L_x^2(n)} \quad (49)$$

در طبقه‌بندی ریز، راه حل تنظیم مقدار ضریب ارتباط هنگام مواجهه با شلیک اشتباهی، استفاده از نورون‌های مجاور است، برای این کار یک برآورد ناپارامتری که نیاز به توزیع طبقه ندارد و محلی‌سازی خوشه‌بندی در نظر گرفته می‌شود. با فرض این که هر نقطه  $d$  بعدی است طبق معادله (50)، چگالی پهنای باند هسته به صورت معادله (51) برآورد می‌شود.

$$x_p \in R^d, p = 1, \dots, n \quad (50)$$

$$f(x) = \frac{1}{nh^d} \sum_{p=1}^n k((x - x_p)/h) \quad (51)$$

به طور معمول از هسته شعاعی متقارن به صورت معادله (52) استفاده می‌شود، در این معادله  $K(x)$  مشخصات هسته برای  $x \geq 0$  است و  $c_{K,d}$  ثابت نرمال شده است. بنابراین چگالی را به صورت معادله (53) می‌توان بازنویسی کرد.

$$K(x) = c_{K,d} K(\|x\|^2) \quad (52)$$

$$f_{h,K}(x) = \frac{c_{K,d}}{nh^d} \sum_{p=1}^n k(\|(x - x_p)/h\|^2) \quad (53)$$

### 6-3- روش تنظیم خودکار پارامتر PCNN برای قطعه‌بندی تصویر

برای رسیدن به تنظیم خودکار پارامتر بدون آموزش و دادگان یک شبکه عصبی پالس همراه ساده (SPCNN) معرفی شده است [44]. در این الگوریتم برای به دست آوردن فرمول کلی از آستانه پویا و فعالیت‌های داخلی از خواص دینامیکی نورون کمک گرفته شده است و پس از استنباط بیان محدوده شدت هر بخش بر اساس فرمول عمومی به دست آمده است. علاوه بر این، از اطلاعات یک تصویر ورودی، انحراف استاندارد، هیستوگرام بهینه تصویر استخراج شده است. یک رابطه مستقیم بین خواص پویای نورون‌ها و خواص مختص هر تصویر ورودی ساخته می‌شود.

#### 6-3-1- مدل SCM

تعداد بسیاری از مدل‌های اصلاح شده شبکه عصبی پالس همراه وجود دارد. ثابت شده است که SCM مدلی است که پیچیدگی محاسباتی پایین‌تر و نرخ‌های دقت بالاتری نسبت به سایر مدل‌ها دارد [45]. در مدل SCM حالت فعالیت نورون با استفاده از معادله (54)، خروجی مدل با استفاده از معادله (55) و آستانه دینامیک عصبی با استفاده از معادله (56) به دست آمده است. تنها تفاوت SPCNN با SCM در زمان شلیک نورون می‌باشد.

$$U_{ij}[n] = e^{-\alpha_f} U_{ij}[n-1] + S_{ij} (1 + \beta V_L \sum_{kl} W_{ijkl} Y_{kl}[n-1]) \quad (54)$$

$$Y_{ij}[n] = \begin{cases} 1, & \text{if } U_{ij}[n] > E_{ij}[n-1] \\ 0, & \text{else} \end{cases} \quad (55)$$

$$E_{ij}[n] = e^{-\alpha_e} E_{ij}[n-1] + V_E Y_{ij}[n] \quad (56)$$

#### 6-4- مدل قطعه‌بندی تکراری آستانه با استفاده از PCNN

این مدل [46] قطعه‌بندی را به وسیله آستانه تکرار شونده شبکه عصبی پالس همراه اصلاح شده، انجام می‌دهد و قطعه‌بندی پیکسل را با خوشه‌بندی جدا کرده است. ابتدا برای یک شبکه عصبی پالس همراه ساده دو ورودی یک آستانه جامع در شرایط شلیک اولیه نورون در نظر می‌گیریم. این آستانه به عنوان مرکز خوشه یک منطقه که در آن سلول‌های عصبی شلیک می‌شوند، شناخته می‌شود. بعد از آن یک روش برای تنظیم خودکار ضریب ارتباط بر اساس حداقل تعیین وزن از مرکز معرفی می‌شود و از طریق تکرار، آستانه را به مرکز همگرایی سوق می‌دهد.



#### 1-4-6- اصلاح شبکه عصبی پالس همراه و تنظیم پارامترها

در مدل ریاضی آستانه تکرار شونده، تغذیه محدوده F به صورت معادله (57) و ارتباط محدوده L به صورت معادله (58) محاسبه شده است. حالت فعالیت نورون با استفاده از معادله (59)، خروجی با معادله (60) و آستانه دینامیک عصبی نورون به وسیله معادله (61) محاسبه شده است.

$$F_x(n) = I_x \quad (57)$$

$$L_x(n) = \sum_{y \in N_x} W_{x,y} Y_y(n-1) \quad (58)$$

$$U_x(n) = F_x(n) \cdot [1 + \beta L_x(n)] \quad (59)$$

$$Y_x = \begin{cases} 1 & U_x(n) > E(n-1) \\ 0 & \text{else} \end{cases} \quad (60)$$

$$E(n) = \underset{E(n)}{\operatorname{argmin}} \sum_{z \in \{Z | Y_z(n)=1\}} K_{\sigma}(y-z)(E(n) - I_z)^2 \quad (61)$$

در معادله (60)،  $\|$  نشان دهنده OR منطقی است و  $K_{\sigma}$  در معادله (61) هسته یک پارامتر مقیاس وقتی  $\sigma > 0$  است. W مربع فاصله اقلیدسی مرکز سلول‌های عصبی از همسایه هشت‌تایی نورون  $N_x$  است که به صورت معادله (62) نیز می‌توان نشان داد.

$$W_{x,y} = \begin{cases} 0 & x = y \\ 1/\|x-y\|^2 & x \neq y \end{cases} \quad (62)$$

در این مدل از یک هسته گاوسی به صورت معادله (63) استفاده شده است که نشان‌دهنده ابعاد داده‌هاست، با استفاده از هسته فوق در مراحل مختلف برای تصویر نوفه‌دار آستانه مناسب پیدا خواهد شد. در این مدل با حداقل واریانس مقدار  $E(n)$ ، آستانه دینامیک عصبی به صورت معادله (64) محاسبه می‌شود.

$$K_{\sigma}(x) = \frac{1}{(\sqrt{2\pi}\sigma)^d} \exp(-\|x\|^2 / (2\sigma^2)) \quad (63)$$

$$E(n) = \frac{\sum_{z \in \Omega} K_{\sigma}(y-z) I_z}{\sum_{z \in \Omega} K_{\sigma}(y-z) \cdot I_z}, \quad \Omega = \{z | Y_z(n) = 1\} \quad (64)$$

$\beta$  ضریب ارتباط یکی از پارامترهای مدولاسیون می‌باشد که هدف آن تنظیم فعالیت‌های داخلی سلول‌های عصبی همسایه است. در بسیاری از پژوهش‌ها این مقدار با آزمایش و خطا بر اساس ویژگی‌های تصویر به دست می‌آید. به طور کلی مقدار بزرگ آن سلول‌های عصبی با روشنایی کم را تشویق به شلیک می‌کند و مقدار کوچک آن باعث کاهش توانایی برای گرفتن سلول عصبی مجاور می‌شود و در نتیجه برای حفظ شباهت بالا در منطقه نورون اخراج می‌شود. در نتیجه تعیین مقدار  $\beta$  در مواجهه شبکه عصبی پالس همراه با تصاویر مختلف یک فرایند پیچیده می‌باشد. در این مدل این مقدار را در ابتدا مجموعه‌ای از نورون‌های نامزد اخراج یا سلول‌های عصبی فعال به صورت معادله (65) تعریف می‌شود. این سلول‌ها می‌توانند توسط سلول‌های عصبی اخراج شده اسیر شده باشند.

$$\alpha\Omega = \{x \mid Y_n(n-1) = 0 \& L_x(n) > 0\} \quad (65)$$

از آنجا که از فعالیت عصبی داخلی، ارزش  $\beta$  مشخص می‌شود. برای به دست آوردن مقدار مناسب  $\beta$  از به حداقل رساندن تابع فاصله مرکز وزنی به شرح معادله (66) استفاده می‌شود.

$$\min_{\beta} \sum_{c=1}^2 \lambda_c (m_c(n-1) - \mu_c)^2, s.t. 0 < \beta \leq 1 \quad (66)$$

در معادلات (67) و (68)،  $\mu_1, \mu_2$  به طور متوسط شدت خاکستری پیکسل مربوط به سلول‌های عصبی و  $\lambda_1, \lambda_2$  نشان‌دهنده وزن و اغلب احتمال رده آن می‌باشد،  $N_1, N_2$  تعداد سلول‌های عصبی هر ناحیه می‌باشد و به‌طور خاص مقدار  $\beta$  با بهینه‌سازی تابع هدف معادله (69) به دست می‌آید.

$$\mu_1 = \frac{1}{N_1} \sum_{x \in \{y \mid U_y(n) \leq E_y(n-1), y \in \alpha\Omega\}} I_x, \lambda_1 = \frac{N_1}{N_1 + N_2} \quad (67)$$

$$\mu_2 = \frac{1}{N_2} \sum_{x \in \{y \mid U_y(n) \leq E_y(n-1), y \in \alpha\Omega\}} I_x, \lambda_2 = \frac{N_2}{N_1 + N_2} \quad (68)$$

$$m_c(n-1) = \frac{\sum_{x \in \{X \mid Y_c(n-1) = c-1\}} I_x}{\sum_{x \in \{X \mid Y_c(n-1) = c-1\}} l_x}, c = 1, 2 \quad (69)$$

## 7- اصلاح فیلتر PCNN برای بهبود کیفیت اثر انگشت

در مقاله [31] یک گام مهم در سیستم اثر انگشت برداشته است. روی اثر انگشت پیش‌پردازش شده است و با افزایش تکرار تصویر توسط فیلتر PCNN به طور قابل توجهی سیستم اثر انگشت ارتقا داده شده است. در بسیاری از سیستم‌های شناسایی از تطبیق جزئیات اثر انگشت و تصویر آن استفاده می‌کنند که کیفیت ضعیف اثر انگشت و اثر جعلی انگشت برای این سیستم‌ها مشکل آفرین می‌باشد. به منظور بهبود سیستم شناسایی باید کیفیت تصویر قبل از شروع تشخیص بالا برده شود.

### 7-1- پیش‌پردازش تصویر اثر انگشت

در تصویر اثر انگشت معمولاً تنها مناطق خطدار نیاز به افزایش وضوح دارند، بنابراین یک تصویر اثر انگشت باید برای حذف پس‌زمینه تقسیم شود. در این مرحله، برای نمایش تصویر اصلی با اندازه  $m \times n$  و اندازه  $w \times w$  برای اندازه تقسیم بلوک استفاده می‌شود. در یک شبکه عصبی مرتبط با تصویر اثر انگشت،  $(i = \text{mod}(m, w), j = \text{mod}(n, w))$  برای نشان دادن تعداد سطر و شماره ستون‌ها است و  $\text{mod}(\dots)$  نشان‌دهنده تابع حسابی مدولار می‌باشد.  $B(i', j')$  نشان‌دهنده  $i'$  امین سطر و  $j'$  امین ستون است و  $1 \leq i' \leq i, 1 \leq j' \leq j$  محدوده‌های  $i'$  و  $j'$  است.

در این شبکه ابتدا  $w$  را مساوی 16 قرار می‌دهیم و آستانه را  $V_{\theta} = 11.5$  در نظر می‌گیریم. تصویر اصلی  $I_{m \times n}$  به مجموعه‌ای از بلوک‌های غیرهمپوشانی  $B(1,1), B(1,2), \dots, B(i,j)$  تقسیم شده است. واریانس استاندارد  $B(i', j')$  توسط معادله (70) محاسبه می‌شود.

$$V(i', j') = \sqrt{\frac{1}{n} [(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2]} \quad (70)$$

در معادله (70) تعداد پیکسل‌ها در بلوک  $B(i, j)$  است.  $x_n$  شدت پیکسل و  $\bar{x}$  مقدار متوسط شدت از بلوک  $B(i, j)$  را نشان می‌دهد. برای هر بلوک  $B(i, j)$  اگر واریانس  $V(i, j)$  و آستانه بیش از  $V_\theta$  باشد، این بلوک به عنوان یک بلوک واقعی در نظر گرفته می‌شود در غیر این صورت به پس‌زمینه تعلق دارد. ماتریس دودویی  $S$  برای ارتباط با سطح آستانه و بلوک به صورت معادله (71) تعریف می‌شود.


$$S(i, j) = \begin{cases} 0, & \text{if } V(i, j) < V_\theta \\ 1, & \text{if } V(i, j) \geq V_\theta \end{cases} \quad (71)$$

یک نشان‌دهنده اثر انگشت بودن و صفر پس‌زمینه است. ماتریس ماسک تصویر  $M_{m \times n}$  است که  $M(m', n') \in \{0, 1\}$  در ماتریس ماسک صفر نشان‌دهنده پیکسل مربوط به عنصر متعلق به اثر انگشت است و یک متعلق به اثر انگشت واقعی است. مقدار کد ماسک از پیکسل تصویر به صورت معادله (72) محاسبه می‌شود.

$$\begin{aligned} M(m', n') &= S(i'_B, j'_B) \\ i'_B &= \text{mod}(m', w) + 1 \\ j'_B &= \text{mod}(n', w) + 1 \end{aligned} \quad (72)$$

## 7-2- نورون مورد استفاده در PCNN بهبود کیفیت تصویر اثر انگشت

در شکل (7) مدل شبکه عصبی پالس همراه استفاده شده در تشخیص اثر انگشت که شامل سه بخش تابع اولیه (پذیرش)، رشته مدولاسیون و مولد پالس است نشان داده شده است.



شکل 7: نورون مدل PCNN. (a) الگوی ارتباط نورون (b) مجموعه‌ی استاندارد ارتباط نورون [31]

در شکل (7)،  $\phi(N_{ab}, O_{m'n'})$  نشان‌دهنده ارتباط ورودی نورون  $N_{ab}$  با مجموعه  $L_{m'n'}$  است که  $O_{m'n'}$  کد ماسک جهت نورون  $N_{ab}$  است.  $w_{ab}$  وزن ارتباط بین  $N_{ab}$  و  $N_{m'n'}$  است و  $w_{m'n'} = 1$  وزن پیوند نورون با خودش را نشان می‌دهد.  $X_{m'n'}$  و  $M_{m'n'}$  نشان‌دهنده سیگنال بار و سیگنال کد ماسک نورون  $N_{m'n'}$  می‌باشد. خروجی مجموع نورون، فعالیت‌های داخلی و آستانه پالس نورون  $N_{m'n'}$  را نشان می‌دهد.  $f(\cdot)$  تابع تصمیم مولد می‌باشد. یک شبکه عصبی تکرار شونده برای نورون  $N_{m'n'}$  در  $t = 0, 1, \dots, +\infty$  به صورت معادله (73) و خروجی آن به صورت معادله (74) محاسبه می‌شود.

$$u_{m'n'}(t+1) = M_{m'n'} \cdot X_{m'n'}(t) + \sum_{ab \in L_{m'n'}} w_{ab} \phi(N_{ab}, O_{m'n'}) \quad (73)$$

$$y_{m'n'}(t+1) = f(u_{m'n'}(t+1) - \theta_{m'n'}(t+1)) \quad (74)$$

که در آن  $L_{m'n'}$  مجموعه شامل  $a \times b$  سلول عصبی در اطراف نورون  $N_{m'n'}$  است. شکل (7) (b) نمایش مجموعه ارتباط به صورت استاندارد  $3 \times 3$  است. تابع مدولاسیون ورودی  $\phi(N_{ab}, O_{m'n'})$  به صورت معادله (75) تعریف می‌شود.

$$\phi(N_{ab}, O_{M_{n'}}) = K_{ab}^{o_{m'n'}} \cdot x_{ab} \cdot \exp(y_{ab}) \quad (75)$$

که  $K_{ab}^{o_{m'n'}}$  کد موقعیت، ارتباط نورون  $N_{ab}$  است و یک عنصر از ماتریس جهت  $K^{o_{m'n'}}$  است.  $w_{ab}$  در تکرار  $t$ ام به صورت معادله (76) تعریف می‌شود.

$$w_{ab} = \begin{cases} \exp(1-d_{ab}), & \text{if } d_{ab} > 0 \\ 1, & \text{if } d_{ab} = 0 \end{cases} \quad (76)$$

$d_{ab}$  فاصله بین ارتباط بین نورون  $N_{m'n'}$  و نورون  $N_{ab}$  می‌باشد و فاصله نورون با خودش  $d_{m'n'} = 0$  است. در شبکه عصبی پالس همراه استفاده شده در [47] آستانه نورون پالس  $\theta_{m'n'}(t)$  است که به صورت تجربی با یک مقدار مشخص مقداردهی اولیه می‌شود و سپس به صورت نمایی کاهش می‌یابد ولی در مدل [31] آن از مجموعه اتصال  $L_{m'n'}$  محاسبه می‌شود. در  $t$  امین تکرار آستانه پالس به صورت معادله (77) به دست می‌آید.

$$\theta_{m'n'}(t) = \varphi(N_{11}, N_{12}, \dots, N_{ab}, \dots) \quad (77)$$

$\varphi(\cdot)$  فرم عملکرد کلی است و باید آن را به تابع خاص در یک کاربرد اختصاص داد.  $f(\cdot)$  نشان‌دهنده تابع مولد پالس است که برای فرمان شلیک یک نورون و تولید یک پالس استفاده می‌شود. خروجی  $f(\cdot)$  دقیقاً خروجی سیگنال  $y_{m'n'}$  برای نورون  $N_{m'n'}$  است. معادله (78) نشان‌دهنده تولید پالس و  $y_{m'n'} = 0$  نشان می‌دهد در لحظه  $t$  نورون شلیک نشده است.

$$y_{m'n'}(t) = f(u_{m'n'} - \theta_{m'n'}) = \begin{cases} 1, & \text{if } u \geq \theta \\ 0, & \text{else} \end{cases} \quad (78)$$

در مدل اصلاح شده شبکه عصبی پالس همراه پیوند به خود نورون با وزن  $w_{m'n'} = 1$  نشان داده می‌شود. علاوه بر آن در  $t$  امین تکرار اگر نورون شلیک شود سیگنال بار نورون با معادله (79) بروزرسانی می‌شود.

$$x_{m'n'}(t) = x_{m'n'}(t-1) + \frac{\delta}{N} \times \sum_{\substack{ab \in L_{m'n'} \\ ab \neq m'n'}} |x_{ab}(t-1) - x_{m'n'}(t-1)| K_{m'n'}^{o_{ab}} \quad (79)$$

تعداد نورون‌ها در موقعیت کد است،  $K_{ab}^{o_{m'n'}} = 1$  و  $|\cdot|$  نشان‌دهنده قدرمطلق تابع است و مقدار  $\delta$  با معادله (80) به دست می‌آید. در معادله (80)  $C_1$  نشان‌دهنده معادله (81) و  $C_2$  نشان‌دهنده معادله (82) است. بنابراین برای شرایط مختلف،  $\delta$  مقدارهای متفاوتی خواهد داشت.

$$\delta = \begin{cases} -1, & \text{if } y_{m'n'}(t) = 1 \text{ and } C_1; \\ 0, & \text{if } y_{m'n'}(t) = 0; \\ 1, & \text{if } y_{m'n'}(t) = 1 \text{ and } C_2; \end{cases} \quad (80)$$

$$x_{m'n'}(t-1) \geq \frac{1}{N} \sum_{ab}^{L_{m'n'}} x_{ab} \times K_{m'n'}^{o_{ab}} \quad (81)$$

$$x_{mn}^{(t-1)} \geq \frac{1}{N} \sum_{ab}^{L \dots} x_{ab} \times K_{ab}^{mn} \quad (82)$$

## 8- نتیجه گیری

در شبکه‌های عصبی پالس همراه هر نورون نشان دهنده پیکسل تصویر ورودی است. اگر پارامترهای شبکه به درستی تنظیم شده باشند، شبکه قدرتمندی خواهیم داشت. شبکه عصبی پالس همراه در طیف گسترده‌ای از برنامه‌های کاربردی و سخت‌افزارهای نهایی قابل پیاده‌سازی می‌باشد.

### سپاسگزاری

با تشکر از سرکار خانم مهندس سمیرا فرامرزیور به پاس زحمات بی‌دریغشان

### مراجع

- [1] M. Monica Subashini and S. K. Sahoo, "Pulse coupled neural networks and its applications," *Expert Systems with Applications*, vol. 41, pp. 3965-3974, 6/15/ 2014.
- [2] D. Zhou, C. Gao, and Y. Guo, "A coarse-to-fine strategy for iterative segmentation using simplified pulse-coupled neural network," *Soft Computing*, vol. 18, pp. 557-570, 2014.
- [3] H. Hikawa, "Frequency-based multilayer neural network with on-chip learning and enhanced neuron characteristics," *Neural Networks, IEEE Transactions on*, vol. 10, pp. 545-553, 1999.
- [4] G. Frank, G. Hartmann, A. Jahnke, and M. Schafer, "An accelerator for neural networks with pulse-coded model neurons," *Neural Networks, IEEE Transactions on*, vol. 10, pp. 527-538, 1999.
- [5] Y. Ota and B. M. Wilamowski, "Analog implementation of pulse-coupled neural networks," *Neural Networks, IEEE Transactions on*, vol. 10, pp. 539-544, 1999.
- [6] J. M. Kinser and T. Lindblad, "Implementation of pulse-coupled neural networks in a CNAPS environment," *Neural Networks, IEEE Transactions on*, vol. 10, pp. 584-590, 1999.
- [7] L. M. Reyneri, "Implementation issues of neuro-fuzzy hardware: going toward HW/SW codesign," *Neural Networks, IEEE Transactions on*, vol. 14, pp. 176-194, 2003.
- [8] J. Chen and T. Shibata, "A neuron-MOS-based VLSI implementation of pulse-coupled neural networks for image feature generation," *Circuits and Systems I: Regular Papers, IEEE Transactions on*, vol. 57, pp. 1143-1153, 2010.
- [9] Z. Wang, Y. Ma, and J. Gu, "Multi-focus image fusion using PCNN," *Pattern Recognition*, vol. 43, pp. 2003-2016, 2010.
- [10] L. Yang and K. Lei, "A new algorithm of image segmentation based on bidirectional search pulse-coupled neural network," in *Computational Aspects of Social Networks (CASoN), 2010 International Conference on*, 2010, pp. 10.1-104
- [11] S. Yin-Mao, Z. Xiao-Hui, and L. Guo-le, "One segmentation algorithm of multi-target image based on improved PCNN," in *2010 2nd International Workshop on Intelligent Systems and Applications*, 2010, pp. 1-4.
- [12] T. Rava, V. Betteiah, and H. S. Ranganath, "Adaptive pulse coupled neural network parameters for image segmentation," *World Acad Sci Eng Technol*, vol. 73, pp. 1046-1052, 2011.
- [13] Y. Xiong, W.-H. Han, K. Zhao, Y.-B. Zhang, and F.-H. Yang, "An analog CMOS pulse coupled neural network for image segmentation," in *Solid-State and Integrated Circuit Technology (ICSICT), 2010 10th IEEE International Conference on*, 2010, pp. 1883-1885.
- [14] J. Li, B. Zou, L. Ding, and X. Gao, "Image segmentation with PCNN model and immune algorithm," *Journal of Computers*, vol. 8, pp. 2429-2436, 2013.
- [15] C. Yao and H.-j. Chen, "Automated retinal blood vessels segmentation based on simplified PCNN and fast 2D-Otsu algorithm," *Journal of Central South University of Technology*, vol. 16, pp. 640-646, 2009.
- [16] N. Chou, J. Wu, J. Bai Bingren, A. Qiu, and K.-H. Chuang, "Robust automatic rodent brain extraction using 3-D pulse-coupled neural networks (PCNN)," *Image Processing, IEEE Transactions on*, vol. 20, pp. 2554-2564, 2011.

- [17] M. M. Subashini and S. K. Sahoo, "Brain MR Image Segmentation for Tumor Detection using Artificial Neural Networks," *International Journal of Engineering & Technology (0975-4024)*, vol. 5, 2013.
- [18] J. Fu, C. Chen, J. Chai, S. T. Wong, and I. Li, "Image segmentation by EM-based adaptive pulse coupled neural networks in brain magnetic resonance imaging," *Computerized Medical Imaging and Graphics*, vol. 34, pp. 308-320, 2010.
- [19] S. Weili, M. Yu, C. Zhanfang, and Z. Hongbiao, "Research of automatic medical image segmentation algorithm based on Tsallis entropy and improved PCNN," in *Mechatronics and Automation, 2009. ICMA 2009. International Conference on*, 2009, pp. 1004-1008.
- [20] A. Ella Hassanien, H. Al-Qaheri, and E.-S. A. El-Dahshan, "Prostate boundary detection in ultrasound images using biologically-inspired spiking neural network," *Applied Soft Computing*, vol. 11, pp. 2035-2041, 2011.
- [21] J. Zhang and J. Hu, "Image segmentation based on 2D Otsu method with histogram analysis," in *Computer Science and Software Engineering, 2008 International Conference on*, 2008, pp. 105-108.
- [22] J. Chen and M. S. Palmer, "Improving English verb sense disambiguation performance with linguistically motivated features and clear sense distinction boundaries," *Language Resources and Evaluation*, vol. 4, pp. 181-208, 2009.
- [23] J. Wolfer, "Pulse coupled neural networks and image morphology for mammogram preprocessing," in *Innovations in Bio-Inspired Computing and Applications (IBICA), 2012 Third International Conference on*, 2012, pp. 286-290.
- [24] I. S. Hage and R. F. Hamade, "Segmentation of histology slides of cortical bone using pulse coupled neural networks optimized by particle-swarm optimization," *Computerized Medical Imaging and Graphics*, vol. 37, pp. 466-474, 2013.
- [25] Z. Wang and Y. Ma, "Medical image fusion using PCNN," *Information Fusion*, vol. 9, pp. 176-185, 2008.
- [26] C. Xi, Z. Wei, and G. Fei, "Image fusion algorithm based on adaptive pulse coupled neural networks in curvelet domain," in *Signal Processing (ICSP), 2010 IEEE 10th International Conference on*, 2010, pp. 845-848.
- [27] M. Bhattacharya, A. Das, and M. Chandana, "GA-based multiresolution fusion of segmented brain images using PD-, T1-and T2-weighted MR modalities," *Neural Computing and Applications*, vol. 21, pp. 1433-1447, 2012.
- [28] W. Huang and Z. Jing, "Multi-focus image fusion using pulse coupled neural network," *Pattern Recognition Letters*, vol. 28, pp. 1123-1132, 2007.
- [29] S. Cheng, M. Qiguang, and X. Pengfei, "A novel algorithm of remote sensing image fusion based on Shearlets and PCNN," *Neurocomputing*, vol. 117, pp. 47-53, 2013.
- [30] X. Gu, "Feature extraction using unit-linking pulse coupled neural network and its applications," *Neural processing letters*, vol. 27, pp. 25-41, 2008.
- [31] L. Ji, X. Pu, and G. Liu, "Modified PCNN Filtering for Fingerprint Enhancement," in *Natural Computation, 2009. ICNC'09. Fifth International Conference on*, 2009, pp. 404-408.
- [32] Z. Shi and J. Hu, "Image edge detection method based on a simplified PCNN model with anisotropic linking mechanism," in *Intelligent Systems Design and Applications (ISDA), 2010 10th International Conference on*, 2010, pp. 330-335.
- [33] X. Li, H. Zheng, and C. Liu, "Face Recognition Scheme based on HSI-PCNN," *Journal of Multimedia*, vol. 8, pp. 573-579, 2013.
- [34] M. Chacon and P. Mendoza, "A PCNN-FCM time series classifier for texture segmentation," in *Fuzzy Information Processing Society (NAFIPS), 2011 Annual Meeting of the North American*, 2011, pp. 1-6.
- [35] X. Jia, "A novel segmentation method using improved PCNN for fabric defect image," in *Signal Processing Systems (ICSPS), 2010 2nd International Conference on*, 2010, pp. V1-388-V1-392.
- [36] Y. Ma, L. Liu, K. Zhan, and Y. Wu, "Pulse-coupled neural networks and one-class support vector machines for geometry invariant texture retrieval," *Image and Vision Computing*, vol. 28, pp. 1524-1529, 2010.

- [37] G. Cai, H. Li, D. Xu, and H. Zhou, "Impulse noise filtering by using an adaptive single-linking pulse coupled neural network," in *Software Engineering and Service Sciences (ICSESS), 2010 IEEE International Conference on*, 2010, pp. 107-110.
- [38] Z. Li, Y. Liu, R. Walker, R. Hayward, and J. Zhang, "Towards automatic power line detection for a UAV surveillance system using pulse coupled neural filter and an improved Hough transform," *Machine Vision and Applications*, vol. 21, pp. 677-686, 2010.
- [39] A. S. Elons, M. Abull-ela, and M. Tolba, "Neutralizing lighting non-homogeneity and background size in PCNN image signature for Arabic Sign Language recognition," *Neural Computing and Applications*, vol. 22, pp. 47-53, 2013.
- [40] L. Ji, Z. Yi, and L. Shang, "An improved pulse coupled neural network for image processing," *Neural Computing and Applications*, vol. 17, pp. 255-263, 2008.
- [41] U. A. Syed, F. Kunwar, and M. Iqbal, "Guided Autowave Pulse Coupled Neural Network (GAPCNN) based real time path planning and an obstacle avoidance scheme for mobile robots," *Robotics and Autonomous Systems*, vol. 62, pp. 474-486, 2014.
- [42] H. J. Caulfield and J. M. Kinser, "Finding the shortest path in the shortest time using PCNN's," *IEEE transactions on neural networks/a publication of the IEEE Neural Networks Council*, vol. 10, pp. 604-606, 1998.
- [43] H. Qu, S. X. Yang, A. R. Willms, and Z. Yi, "Real-time robot path planning based on a modified pulse-coupled neural network model," *Neural Networks, IEEE Transactions on*, vol. 20, pp. 1724-1739, 2009.
- [44] Y. Chen, S.-K. Park, Y. Ma, and R. Ala, "A new automatic parameter setting method of a simplified PCNN for image segmentation," *Neural Networks, IEEE Transactions on*, vol. 22, pp. 880-892, 2011.
- [45] K. Zhan, H. Zhang, and Y. Ma, "New spiking cortical model for invariant texture retrieval and image processing," *Neural Networks, IEEE Transactions on*, vol. 20, pp. 1980-1986, 2009.
- [46] C. Gao, D. Zhou, and Y. Guo, "An iterative thresholding segmentation model using a modified pulse coupled neural network," *Neural processing letters*, vol. 39, pp. 81-95, 2014.
- [47] X. Gu, D. Yu, and L. Zhang, "Image shadow removal using pulse coupled neural network," *Neural Networks, IEEE Transactions on*, vol. 16, pp. 692-698, 2005.