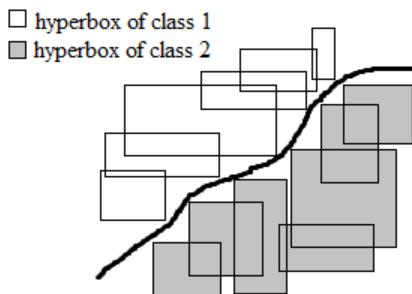


# شبکه عصبی فازی مین-ماکس چندسطحی با باکس‌های وزن دار

رضا داوطلب، محمدعلی بالافر و محمدرضا فیضی درخشی



شکل ۱: تصویر هایپرباکس‌های ایجاد شده توسط شبکه FMM [۳۱].

یک ساختار مفهومی به نام هایپرباکس<sup>۱</sup> استفاده می‌کند که هر هایپرباکس یک جعبه محدب در فضای نمونه بوده و محدوده تحت پوشش آن توسط دو نقطه  $V$  و  $W$  مشخص می‌شود که هر یک نقطه‌ای از فضای  $n$  بعدی نمونه‌ها بوده و به ترتیب متناظر با نقاط  $\min$  و  $\max$  هایپرباکس هستند. هر هایپرباکس متعلق به یک کلاس بوده و ناحیه تحت پوشش آن مناسب به کلاسی است که هایپرباکس مذکور به آن کلاس تعلق دارد. هایپرباکس‌ها در طول فاز آموزش گسترش می‌یابند تا همه فضای نمونه‌ها را تحت پوشش خود قرار دهند ولی در پایان فاز آموزش، بین هایپرباکس‌هایی که متعلق به یک کلاس نیستند نباید هیچ همپوشانی وجود داشته باشد و حداقل میزان گسترش هر هایپرباکس به وسیله پارامتر  $\theta$  (که توسط کاربر مشخص می‌شود) کنترل می‌گردد.

هر هایپرباکس متعلق به یکی از کلاس‌ها بوده و محدوده‌ای از فضای نمونه‌ها را تحت پوشش قرار می‌دهد و طبق (۱) تعریف می‌شود

$$B_j = \{X, V_j, W_j, f(X, V_j, W_j)\}, \quad \forall X \in I^n \quad (1)$$

که در آن  $X$  نمونه ورودی،  $V_j$  و  $W_j$  به ترتیب نقاط  $\min$  و  $\max$  و  $f(X, V_j, W_j)$  تابع عضویت هایپرباکس  $B_j$  هستند. هایپرباکس‌هایی که کلاس می‌تواند همپوشانی داشته باشند ولی هایپرباکس‌های متعلق به دو کلاس مختلف نبایستی با یکدیگر همپوشانی داشته باشند. در شکل ۱ نمایی از هایپرباکس‌های نهایی این الگوریتم برای دسته‌بندی در یک فضای دو بعدی و برای نمونه‌های دو کلاس مختلف نشان داده شده است.

در این روش محدوده نمونه‌های کلاس  $C_k$  با استفاده از هایپرباکس‌های کلاس  $C_k$  و به صورت زیر به دست می‌آید

$$C_k = \bigcup_{j \in k} B_j \quad (2)$$

در این رابطه  $k$  مجموعه اندیس‌هایی است که هایپرباکس‌های متناظر، متعلق به کلاس  $k$  هستند. این هایپرباکس‌ها طی فاز یادگیری تشکیل و محدوده آنها تنظیم می‌شود. در فاز آزمایش<sup>۲</sup> از همین هایپرباکس‌ها و تابع عضویتشان استفاده می‌کنیم تا نمونه ورودی را به یکی از کلاس‌ها مناسب کنیم.

- 5. Hyperbox
- 6. Test

چکیده: در این مقاله شبکه عصبی فازی مین-ماکس چندسطحی با باکس‌های وزن دار (WL-FMM) برای استفاده در کلاس‌بندی ارائه می‌گردد که یک ابزار یادگیری با نظرات بسیار سریع بوده و قادر به یادگیری داده‌ها به صورت برخط و تک‌گذار است. در این روش برای حل مشکل نواحی همپوشان که از مشکلات همیشگی روش‌های فازی مین-ماکس بوده، از باکس‌هایی با اندازه کوچک‌تر و وزن بیشتر استفاده می‌شود. این کار باعث افزایش دقت طبقه‌بندی شبکه در نواحی مزدی نمونه‌ها می‌گردد. همچنین با توجه به تغییراتی که در ساختار الگوریتم داده شده و بر اساس نتایج آزمایشی به دست آمده، روش ارائه شده نسبت به روش‌های مشابه از بیچیدگی زمانی و مکانی کمتری برخوردار بوده و نسبت به پارامترهایی که از طرف کاربر مشخص می‌شود، حساسیت کمتری دارد.

**کلیدواژه:** طبقه‌بندی، شبکه عصبی، فازی، مین-ماکس، یادگیری ماشین، وزن دار.

## ۱- مقدمه

منطق فازی اولین بار توسط پرفسور لطفی‌زاده ارائه شد [۱] که با توجه به سازگاری اصول ارائه شده در مجموعه‌های فازی و بسیاری از مسائل دنیای واقعی و همچنین اهمیت و کارایی بالای آن در زمینه بازناسانی الگو، شاهد استفاده روزافزون از این منطق در حوزه بازناسانی الگو هستیم [۲]. در موارد بسیاری منطق فازی با دیگر ابزارهای بازناسانی الگو ادغام شده و ابزار جدیدتری ارائه می‌شود که شبکه‌های نروفازی<sup>۳</sup> از جمله آنهاست که با ترکیب منطق فازی و شبکه‌های عصبی مصنوعی ایجاد شده است [۳] تا [۵]. این شبکه‌ها با توجه به قدرت بازناسانی بالای سیستم‌های فازی و نیز قدرت محاسباتی بالای شبکه‌های عصبی، ابزار قدرتمندی در این حوزه بازناسانی الگو هستند [۶] تا [۸].

شبکه‌های<sup>۴</sup> FMM نوع خاصی از شبکه‌های نروفازی است که در سال ۱۹۹۲ توسط Simpson ارائه شده است [۹]. استفاده از شبکه‌های FMM در حوزه یادگیری ماشین در مقایسه با دیگر روش‌های یادگیری کارایی بالایی داشته و استفاده روزافزونی دارد [۱۰]. از مزایای این شبکه‌ها می‌توان به برخط‌بودن و تک‌گذار بودن فاز آموزش<sup>۵</sup> این شبکه‌ها اشاره کرد که در زمان بسیار کمی انجام می‌شود. این شبکه‌ها برای انجام طبقه‌بندی و خوشه‌بندی مورد استفاده قرار گرفته است [۹] و [۱۱] و از

این مقاله در تاریخ ۲ بهمن ماه ۱۳۹۳ دریافت و در تاریخ ۳ خرداد ماه ۱۳۹۵ بازنگری شد.

رضا داوطلب، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، (email: r.davtalab@tabrizu.ac.ir)  
محمدعلی بالافر، گروه مهندسی کامپیوتر، دانشگاه تبریز، تبریز، (email: balafarila@yahoo.com)  
محمدرضا فیضی درخشی، گروه مهندسی کامپیوتر، دانشگاه تبریز، تبریز، (email: mfeizi@tabrizu.ac.ir)

1. Neurofuzzy
2. Fuzzy Min-Max
3. Single Pass
4. Train

## ۲- سابقه و کارهای مشابه

کارهای زیادی بر پایه شبکه‌های FMM و برای بهبود روش کلاسیک آن برای انجام طبقه‌بندی ارائه شده است [۷ تا [۹] و [۱۳] تا [۱۶] و [۳۰]. در این قسمت ابتدا نگاهی کوتاه به FMM اولیه داریم و پس از آن مروری کوتاه به مهم‌ترین روش‌های سال‌های اخیر داشته و به بررسی سیر تکاملی این روش‌ها و همچنین مزایا و معایب هر یکی پردازیم.

### ۱-۲ روش FMM اولیه

همان طور که ذکر گردید این روش، برای اولین بار توسط Simpson [۹] ارائه شده است که از ساختار بسیار ساده‌ای استفاده می‌کند. همان طور که در شکل ۲-الف مشخص است این شبکه‌ها مشکل از سه لایه است. لایه اول این شبکه ( $F_A$ ) مربوط به نمونه‌های ورودی، لایه دوم ( $F_B$ ) مربوط به هایپرباکس‌ها و لایه سوم ( $F_C$ ) نیز مسئول تولید خروجی خواهد بود که هر یک از هایپرباکس‌ها به عنوان گره‌ای در لایه میانی ( $F_B$ ) شبکه FMM قرار می‌گیرند کهتابع عضویت هر هایپرباکس به عنوان تابع گذار گره متانظر خواهد بود. شکل ۲-ب نیز جزئیات بیشتر یک هایپرباکس را نشان می‌دهد. هر یک از گره‌های لایه  $F_A$  به همه گره‌های لایه  $F_B$  متصل هستند و هر یک از این اتصالات دارای ۲ وزن گره‌های لایه  $F_B$  بود، یکی  $V_{ij}$  و دیگری  $W_{ij}$  که نقاط  $\min$  و  $\max$  را خواهند بود، یکی  $V_{ij}$  و دیگری  $W_{ij}$  که نقاط  $\min$  و  $\max$  را مشخص می‌کنند،  $i$  شماره گره لایه اول (شماره بعد) و  $j$  شماره گره لایه دوم (شماره هایپرباکس) است. همچنین همه گره‌های لایه  $F_B$  به لایه  $F_C$  متصل است و وزن هر یک از این اتصالات با (۳) و تابع گذار هر یک از گره‌های لایه آخر کهتابع عضویت هر یک از کلاس‌ها را مشخص می‌کند با (۴) مشخص می‌شود

$$u_{ij} = \begin{cases} 1, & \text{if } \{b_j \in C_i\} \\ 0, & \text{if } \{b_j \notin C_i\} \end{cases} \quad (3)$$

$$C_k = \max_{j=1, \dots, m} b_j u_{kj} \quad (4)$$

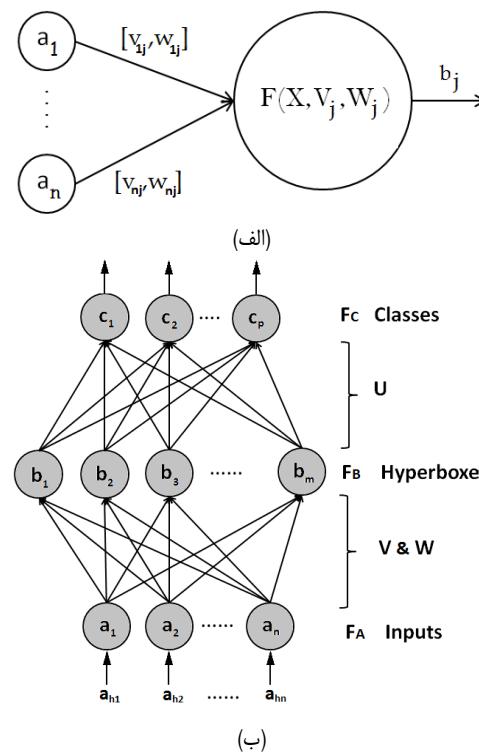
تابع عضویت استفاده شده در هایپرباکس‌ها برای کاربردهای کلاس‌بندی، طبق (۵) محاسبه می‌گردد

$$b_j(A_h) = \frac{1}{2n} \sum_{i=1}^n [\max(\cdot, 1 - \max(\cdot, \gamma \min(1, a_{hi} - w_{ji}))) + \max(\cdot, 1 - \max(\cdot, \gamma \min(1, v_{ij} - a_{hi})))] \quad (5)$$

در این رابطه،  $a_{hi}$  بعد  $i$  ام از نمونه آموزشی  $A_h$  و  $w_{ji}$  نقطه هایپرباکس  $j$  در بعد  $i$  ام است و  $\gamma$  ضریبی بین صفر تا یک است که توسط کاربر مشخص می‌شود. شکل ۳ مقدار این تابع را در محدوده تحت پوشش یک هایپرباکس به خوبی نشان می‌دهد.

همه هایپرباکس‌ها در فاز یادگیری ساخته می‌شوند. فاز یادگیری خود شامل سه بخش است. با ورود نمونه  $X$  ابتدا بررسی می‌شود که آیا این نمونه در محدوده حداقل یکی از هایپرباکس‌ها قرار دارد یا نه. اگر نمونه در محدوده حداقل یکی از هایپرباکس‌ها قرار داشت نمونه بعدی بررسی خواهد شد ولی اگر نمونه  $X$  در محدوده هیچ یک از هایپرباکس‌های موجود نباشد مراحل زیر به ترتیب انجام می‌شود:

(الف) گسترش<sup>۱</sup>: در این مرحله سعی می‌شود هایپرباکسی یافت شود که متعلق به همان کلاسی باشد که  $X$  متعلق به آن است و همچنین با توجه به رابطه زیر آن قدر قابل گسترش باشد که نمونه



شکل ۲: شبکه FMM، (الف) شماتیکی شبکه FMM و (ب) جزئیات بیشتر یک هایپرباکس (برگرفته از [۱۵]).

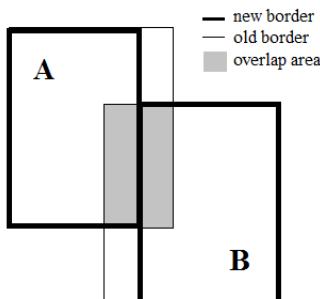
نواحی همپوشان ایجاد شده بین هایپرباکس‌های کلاس‌های مختلف از مهم‌ترین مشکلات روش‌های FMM است که روش‌های ابتدایی ارائه شده [۷] و [۹] برای حل مشکل نواحی همپوشان، هایپرباکس‌های شرکت‌کننده در ناحیه همپوشان را هرس<sup>۱</sup> می‌کنند. این نحوه مدیریت تأثیر نامطلوبی بر کارایی این شبکه‌ها داشته و در روش‌های جدیدتر [۶، [۸] و [۱۲] و [۱۳] برای مدیریت این نواحی از گره‌هایی شبیه به هایپرباکس‌های معمولی استفاده شده است که تابع گذار<sup>۲</sup> یا تابع عضویت<sup>۳</sup> این گره‌ها نحوه طبقه‌بندی نمونه‌ها را در ناحیه همپوشان، مشخص می‌کند. این روش‌ها نسبت به روش‌های اولیه کارایی بهتری داشته و شاخص ترین آنها که از کارایی بالاتری نسبت به روش‌های مشابه برخوردار است روش DCFMN است که توسط Zhang در سال ۲۰۱۱ ارائه شده [۱۴] و از یک تابع عضویت مبتنی بر فاصله نمونه تا مرکز داده‌های موجود در هایپرباکس بهره می‌برد که نتایج نسبتاً خوبی ارائه می‌دهد. در پژوهش دیگری داطلب و همکاران [۱۵] با استفاده از یک ساختار چندلایه درختی (MLF) عملکرد این شبکه‌ها را بهبود دادند ولی با توجه به ساختار پیچیده‌ای که این روش دارد، در مواردی که درصد بالایی از نمونه‌ها در نواحی مرزی قرار دارند از کارایی لازم برخوردار نیست.

در این مقاله شبکه عصبی فازی مین-ماکس چندسطحی با باکس‌های وزن دار (WL-FMM) ارائه می‌شود که در آن اشکالات ساختاری الگوریتم MLF برطرف شده و با توجه به تغییرات انجام شده پیچیدگی فضایی و زمانی آن بسیار کمتر شده و همچنین طبق نتایج به دست آمده در زیادی دقت طبقه‌بندی نیز افزایش داشته است. نتایج به دست آمده از پیاده‌سازی این روش و مقایسه کارایی آن با سایر روش‌های FMM در قسمت نتایج آزمایشی ارائه گردیده است.

1. Contraction
2. Transition Function
3. Membership Function

4. Activation Function

5. Expansion



شکل ۴: نحوه از بین بردن ناحیه همپوشان [۳۱].

سه مرحله فوق به ازای تمامی نمونه‌های آموزشی اجرا می‌گردد تا هایپرباکس‌های مورد نیاز ساخته شوند.

ذکر این نکته ضروری است که هرچه اندازه پارامتر  $\theta$  بزرگ‌تر باشد تعداد هایپرباکس‌ها کمتر بوده و سیستم پیچیدگی کمتری خواهد داشت. ولی در این حالت به دلیل افزایش نواحی همپوشان و مشکلاتی که سیستم برای حذف این همپوشانی‌ها با آن موجه می‌شود، دقت سیستم پایین خواهد بود. در صورتی که حداقل اندازه هایپرباکس‌ها ( $\theta$ ) مقدار کوچکی انتخاب شود، سیستم از پیچیدگی بیشتری برخوردار بوده و ضمن اشغال فضای بیشتر، مدت زمان طولانی‌تری برای پردازش صرف خواهد نمود، یعنی یک trade off بین میزان پیچیدگی سیستم و دقت آن وجود دارد.

## ۲-۲ روش GFMM

روش GFMM توسط Gabrys و Bargiela در سال ۲۰۰۰ ارائه شد [۷] و در آن تغییرات خوبی جهت بهبود کارایی روش FMM ارائه شده است که مهتم‌ترین ویژگی‌های این روش به شرح زیر است:

(الف) در روش FMM نمونه ورودی به صورت یک نقطه از Crisp فضای نمونه است ولی در روش GFMM نمونه ورودی علاوه بر نقاط Crisp می‌تواند به صورت یک هایپرباکس فازی در فضای نمونه باشد که در این حالت در مرحله expansion برای عملگر max به جای نقطه از  $w$  هایپرباکس ورودی و برای عملگر min از  $v$  هایپرباکس ورودی استفاده می‌شود.

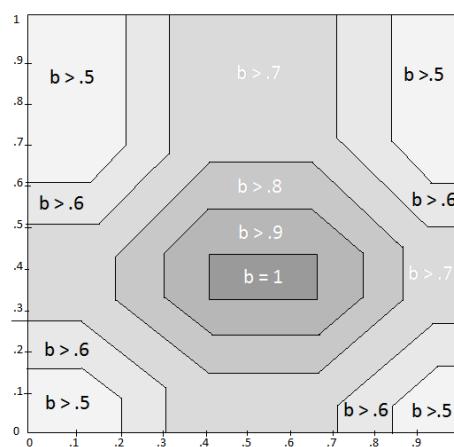
(ب) تابع عضویت هایپرباکس‌ها در روش FMM از (۳) محاسبه می‌شود ولی همان طور که در شکل ۳ نشان داده است در این رابطه با افزایش فاصله از هایپرباکس مقدار تابع عضویت به صورتی ناموزون و غیر یکنواخت کاهش می‌یابد. بنابراین در این روش به جای رابطه مذکور از (۹) استفاده شده است

$$b_j(A_h) = \min_{i=1 \dots n} (\min([1 - f(a_{hi}^u - w_{ji}, \gamma)], [1 - f(v_{ij} - a_{hi}^l, \gamma)])) \quad (9)$$

که در آن  $\gamma$  عددی بین صفر و یک است که توسط کاربر مشخص می‌شود و همچنین تابع  $f$  از (۱۰) به دست می‌آید

$$f(x, y) = \begin{cases} 1, & \text{if}(xy > 1) \\ xy, & \text{if}(x \leq xy \leq 1) \\ ., & \text{if}(xy < .) \end{cases} \quad (10)$$

نحوه تغییر مقدار تابع  $b_j$  در شکل ۵ آمده است (برگرفته شده از [۷]). همان طور که پیداست برخلاف (۳) در این رابطه با دورشدن از هایپرباکس



شکل ۳:تابع عضویت استفاده شده در روش FMM برای حالت دو بعدی [۱۵].

$X$  را در بر گیرد. در صورتی که چنین هایپرباکسی یافت نشد یک هایپرباکس جدید ایجاد شده و  $X$  به عنوان نقاط min و max آن تعیین می‌گردد

$$n\theta \geq \sum (\max(b_{ji}, x_{hi}) - \min(v_{ji}, x_{hi})) \quad (6)$$

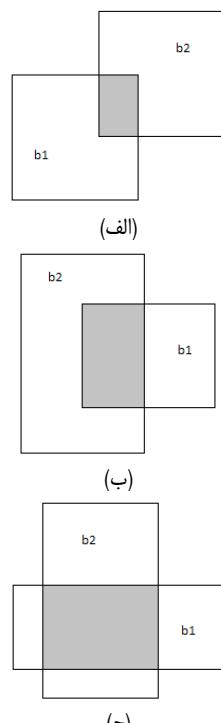
که در آن  $\theta$  پارامتری است که از طرف کاربر مشخص می‌گردد.  
ب) بررسی همپوشانی<sup>۱</sup>: در این مرحله بررسی می‌شود که هایپرباکس گسترش یافته یا تولید شده مرحله قبل با تمامی هایپرباکس‌هایی که متعلق به کلاس‌های دیگری هستند همپوشانی نداشته باشند. دو هایپرباکس  $B_r$  و  $B_k$  در صورتی با هم همپوشانی دارند که به ازای هر یک از ابعاد فضای نمونه در یکی از ۴ حالت (۷) قرار داشته باشند که برای از بین بردن این همپوشانی از بعدی استفاده می‌شود که به ازای آن کمترین همپوشانی وجود دارد (این بعد با اندیس  $d$  نشان می‌شود)

$$\begin{aligned} case 1: v_{ji} &< v_{ki} &< w_{ji} &< w_{ki} \\ case 2: v_{ki} &< v_{ji} &< w_{ki} &< w_{ji} \\ case 3: v_{ji} &< v_{ki} &\leq w_{ki} &< w_{ji} \\ case 4: v_{ki} &< v_{ji} &\leq w_{ji} &< w_{ki} \end{aligned} \quad (7)$$

ج) انقباض یا هرس کردن: در صورتی که همپوشانی وجود نداشته باشد نیازی به اجرای این مرحله نیست و در غیر این صورت با توجه نوع همپوشانی در بعد  $d$ ، یکی از حالات (۸) اجرا می‌شود که در

شکل ۴ نحوه انجام contraction را مشاهده می‌کنید

$$\begin{aligned} case 1: v_{jd} &< v_{kd} &< w_{jd} &< w_{kd} \\ v_{kd}^{new} &= w_{jd}^{new} = \frac{v_{kd}^{old} + w_{jd}^{old}}{2} \quad \text{or} \quad , w_{jd}^{new} = v_{kd}^{old} \\ case 2: v_{kd} &< v_{jd} &< w_{kd} &< w_{jd} \\ v_{jd}^{new} &= w_{kd}^{new} = \frac{v_{jd}^{old} + w_{kd}^{old}}{2} \quad \text{or} \quad , v_{jd}^{new} = w_{kd}^{old} \\ case 3: v_{jd} &< v_{kd} &\leq w_{kd} &< w_{jd} \\ \text{if}(w_{kd} - v_{jd} &< w_{jd} - v_{kd}), v_{jd}^{new} = w_{kd}^{old}; \text{else} v_{jd}^{new} = v_{kd}^{old} \\ case 4: v_{kd} &< v_{jd} &\leq w_{jd} < w_{kd} \\ \text{if}(w_{kd} - v_{jd} &< w_{jd} - v_{kd}), w_{kd}^{new} = v_{jd}^{old}; \text{else} v_{kd}^{new} = w_{jd}^{old} \end{aligned} \quad (8)$$



شکل ۶: انواع همپوشانی‌ها در روش FMCN [۳۱]

شد [۸]. در این روش نواحی همپوشان با استفاده از گره‌های جبرانی مدیریت می‌شوند که خود به دو دسته خاص تر تقسیم می‌شوند که این دو دسته عبارتند از OCN و CCN<sup>۳</sup>. دسته اول جهت مدیریت نواحی همپوشان ساده (شکل ۶-الف) و دسته دوم برای مدیریت نواحی همپوشانی پیچیده‌تر (حالی که مانند شکل ۶-ب، بخشی از هایپرباکس یک کلاس کاملاً در داخل هایپرباکس از کلاس دیگر قرار دارد) استفاده می‌شود.

می‌توان گفت این روش، بهبودیافته روش EFC [۶] است با افزودن بخشی برای نحوه مدیریت نواحی همپوشان نوع اول (OCN). البته نوع دیگری از نواحی همپوشان نیز وجود دارد که در این روش در نظر گرفته نشده و آن حالتی است که دو هایپرباکس متعلق به دو کلاس مختلف همدیگر را قطع کرده‌اند (شکل ۶-ج).

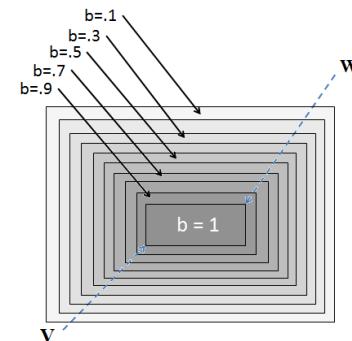
در فاز آموزش روش FMCN، مانند شبکه‌های قبلی هایپرباکس‌هایی برای پوشش نواحی کلاس‌ها ایجاد می‌شود که این هایپرباکس‌ها در قسمت OCN قرار گرفته و از (۸) به عنوانتابع عضویت استفاده می‌کنند. به ازای هر ناحیه همپوشان که در فاز آموزش به وجود می‌آید یک گره جبرانی<sup>۴</sup> ایجاد می‌شود. در صورتی که این ناحیه همپوشان از نوع اول (شکل ۶-الف) باشد گره اضافه شده از نوع  $d$  (شکل ۷-الف) بوده و به قسمت OCN شبکه اضافه خواهد شد و اگر ناحیه همپوشان از نوع دوم باشد گره مذکور از نوع  $e$  (شکل ۷-ب) خواهد بود که به قسمت CCN شبکه اضافه می‌شود. همان طور که از شکل ۷ پیداست گره‌های نوع OCN دارای دو خروجی و گره‌های نوع CCN دارای یک خروجی هستند. در فاز آزمایش این روش برای تابع عضویت کلاس نام از (۱۱) استفاده می‌شود

$$\mu_i = c_i + o_i \quad (11)$$

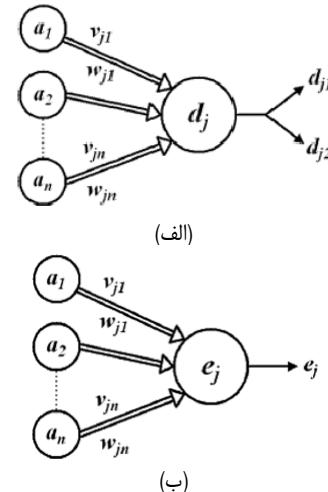
3. Overlap Compensation Neuron

4. Containment Compensation Neuron

5. Compensation



شکل ۵: تابع عضویت استفاده شده در روش GFMM برای حالت دو بعدی [۱۵].



شکل ۷: (الف) شمای یک گره OCN و (ب) شمای یک گره CCN در شبکه FMCN (برگرفته از [۸]).

در جهات مختلف، مقدار تابع عضویت با شبیه یکنواخت کم می‌شود که این امر باعث افزایش کارایی این روش نسبت به روش FMM معمولی شده است.

(الف) از GFMM می‌توان علاوه بر طبقه‌بندی و خوشبندی محض برای حالت ترکیبی این دو روش نیز استفاده کرد. برای پیاده‌سازی این حالت یک کلاس جداگانه به عنوان کلاس unlabeled در نظر گرفته می‌شود که همپوشانی هایپرباکس‌های این کلاس با هایپرباکس‌های دیگر کلاس‌ها مجزا است.

(ب) در این روش با توجه به شرایط اجرای الگوریتم و میزان همپوشانی‌های ایجاد شده می‌توان حداکثر اندازه هایپرباکس‌ها را تغییر داده و مقداری که بهترین نتیجه را داشته باشد به عنوان پارامتر نهایی برگردید. به عبارت دیگر این روش تک‌گذار نبوده و با چند بار اجرا بهترین مقدار پارامتر  $\theta$  را برمی‌گزیند.

با توجه به موارد گفته شده روش GFMM تغییرات خوبی جهت بهبود کارایی و افزایش بازه عملکرد<sup>۵</sup> روش‌های مبتنی بر FMM ایجاد کرده است اما این روش رویکرد جدیدی برای مقابله با مشکل نواحی همپوشان ارائه نداده و این مشکل همچنان پایرجاست.

### ۳-۲ روش FMCN<sup>۶</sup>

روش FMCN<sup>۶</sup> در سال ۲۰۰۷ توسط Biswas و Nandedkar ارائه

1. Generalization
2. Fuzzy Min-Max Neural Network Classifier with Compensatory Neurons

همپوشانی دارد. در این روش سعی شده تا با استفاده از یک ساختار چندسطحی، نمونه‌هایی که در ناحیه همپوشانی قرار گرفته‌اند، بار دیگر در سطوح بعدی با دقت بیشتر طبقه‌بندی شوند. این شبکه از یک ساختار چندلایه درختی استفاده می‌کند که هرچه از لایه اول به سمت لایه‌های پایانی حرکت می‌کنیم از اندازه باکس‌ها و فضایی که تحت پوشش آنها قرار دارد کاسته شده ولی بر دقت تصمیم آنها افزوده می‌شود. در شکل ۹ نحوه تشکیل باکس‌های لایه اول و دوم پس از فاز یادگیری نشان داده شده‌اند.

هر گره از این درخت، مسئول انجام کلاس‌بندی در ناحیه خاصی از فضای نمونه بوده و منتظر با یک زیرشبکه است که در شکل ۱۰-ب زیرشبکه‌ای را مشاهده می‌کنید که در گره  $A$  ایجاد شده و با گره (زیرشبکه) خواهیم داشت که بیشتر مسئول دسته‌بندی نواحی یک‌نواخت بزرگ است. لایه دوم، نواحی همپوشان لایه اول را پوشش می‌دهد و لایه سوم همین کار را برای نواحی همپوشان لایه دوم انجام داده و به همین ترتیب هر یک از زیرشبکه‌های لایه  $i$  ام یکی از نواحی همپوشان لایه  $-1-i$  ام را تحت پوشش داشته و در واقع مسئول انجام دسته‌بندی در ناحیه مذکور خواهد بود.

هر زیرشبکه از دو قسمت اصلی<sup>۳</sup> HBS و<sup>۴</sup> OLS تشکیل شده است. در قسمت HBS باکس‌های معمولی (HyperBox) قرار دارند که برای دسته‌بندی نمونه‌ها استفاده می‌شوند و در قسمت OLS "باکس‌های همپوشان" (OverlapBox) قرار دارند که محدوده نواحی همپوشان زیرشبکه را مشخص می‌کنند و به ازای هر یک از این همپوشان‌ها یک زیرشبکه در لایه بعدی ساخته می‌شود.تابع گذار گره  $G$  نیز با توجه به مقدار ورودی فعال‌ساز زیرشبکه، خروجی زیرشبکه را طبق رابطه زیر مشخص می‌کند

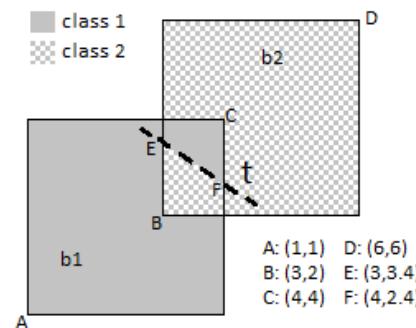
$$g_a = e_a \times (c - o) \quad (18)$$

که در آن  $c$  و  $o$  به ترتیب خروجی قسمت‌های HBS و OLS بوده و  $e_x$  ورودی فعلی زیرشبکه است که مقدار آن در زیرشبکه والد تولید می‌شود.

برای اطمینان بیشتر از کوچک‌بودن باکس‌های زیرشبکه فرزند نسبت به باکس‌های والد، برای تعیین حداقل اندازه باکس‌ها (پارامتر  $\theta$ ) در زیرشبکه فرزند از رابطه زیر استفاده می‌کنیم

$$\theta_c = \frac{\theta_p}{\gamma} \quad (19)$$

که در آن  $\theta_c$  و  $\theta_p$  به ترتیب حداقل اندازه باکس‌ها در زیرشبکه فرزند و والد و  $\gamma$  عدد صحیحی بین ۲ تا ۱۰ است. روند ساخت هایپرباکس‌های معمولی دقیقاً مانند روش FMM کلاسیک است با این تفاوت که در اینجا مرحله هرس یا Contraction را نداریم. در مرحله بعد همه نواحی همپوشان زیرشبکه شناسایی شده و به ازای هر یک، یک "باکس همپوشان" در قسمت OLS و نیز یک زیرشبکه در لایه بعد ایجاد می‌شود. "باکس همپوشان" محدوده ناحیه همپوشان را مشخص می‌کند و زیرشبکه ایجادشده نیز با استفاده از نمونه‌های موجود در این ناحیه آموخت می‌باید. در نهایت زیرشبکه زر با استفاده از یال  $r_e$  که همواره دارای وزنی برابر ۱ است به زیرشبکه والد خود متصل شده و عملکرد آن



شکل ۸: نحوه دسته‌بندی روش [۳۱] FMCN.

در این رابطه  $c_i$  تابع عضویت به دست آمده از قسمت CLS شبکه است که از (۱۲) و  $o_i$  تابع عضویت قسمت جبرانی است که از (۱۳) به دست می‌آید

$$c_k = \max_{j=1 \dots m} b_j u_{kj} \quad (12)$$

$$o_k = \min(c_{oi}, c_{ci}) \quad (13)$$

در این رابطه نیز  $c_{oi}$  و  $c_{ci}$  به ترتیب با استفاده از (۱۴) و (۱۵) محاسبه می‌شوند

$$c_{oi} = \min_{j=1 \dots k} (d_j y_{ji}) \quad (14)$$

$$c_{ci} = \min_{j=1 \dots k} (e_j z_{ji}) \quad (15)$$

در این روابط خروجی گره‌های  $d$  با  $d_j$  و خروجی گره‌های  $e$  با  $e_j$  مشخص شده که به ترتیب در قسمت‌های OCN و CCN قرار داشته و طبق (۱۶) و (۱۷) محاسبه می‌شوند

$$d_{jp} = U(b_j(A_h, v_j, w_j) - 1) \times (-1 + \frac{1}{n} \sum_{i=1}^n \max(\frac{a_{hi}}{w_{pi}}, \frac{v_{pi}}{a_{hi}})) \quad (16)$$

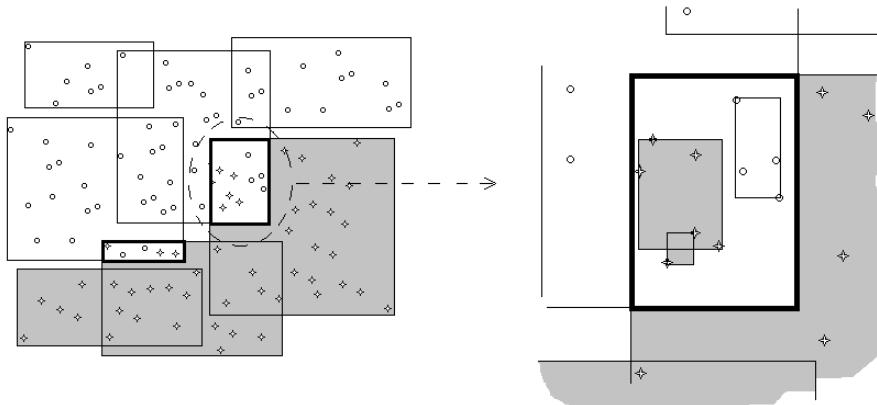
$$e_j = -1 \times U(b_j(A_h, v_j, w_j) - 1) \quad (17)$$

در این روابط  $V_j$  و  $W_j$  به ترتیب نقاط  $\min$  و  $\max$  ناحیه همپوشان بوده و  $A_h$  نمونه آزمایشی است.  $v_{pi}$  و  $w_{pi}$  نیز به ترتیب نشان‌دهنده نقاط  $\min$  و  $\max$  هایپرباکس  $p$  در بعد  $i$  هستند. در شکل ۸ نحوه کلاس‌بندی محدوده محصور بین دو هایپرباکس از دو کلاس مختلف را مشاهده می‌کنید.

در سال‌های اخیر روش‌های دیگری بر پایه این روش ارائه شده که با انجام تغییراتی، نتایج آن را بهبود داده‌اند که از آن جمله می‌توان به [۳۱] اشاره نمود که از یک تابع عضویت شاعر محور در هایپرباکس‌ها استفاده کرده و تغییراتی را در نحوه مدیریت نواحی همپوشان انجام داده است. نتایج به دست آمده از پیاده‌سازی این روش‌ها نشان‌دهنده بهبود نسبی دارای مشکلاتی هستند که از جمله می‌توان به عدم مدیریت مناسب نواحی همپوشان و دقت و سرعت پایین در مقایسه با روش‌های قبلی اشاره نمود.

## ۴-۲ روش MLF

روش<sup>۱</sup> MLF که در ۲۰۱۴ ارائه شده [۱۵] نگاه متفاوتی به مسئله



شکل ۹: نحوه مدیریت نواحی همپوشان و طبقه‌بندی نمونه‌های آنها در لایه بعدی شبکه برگرفته شده از [۱۵].

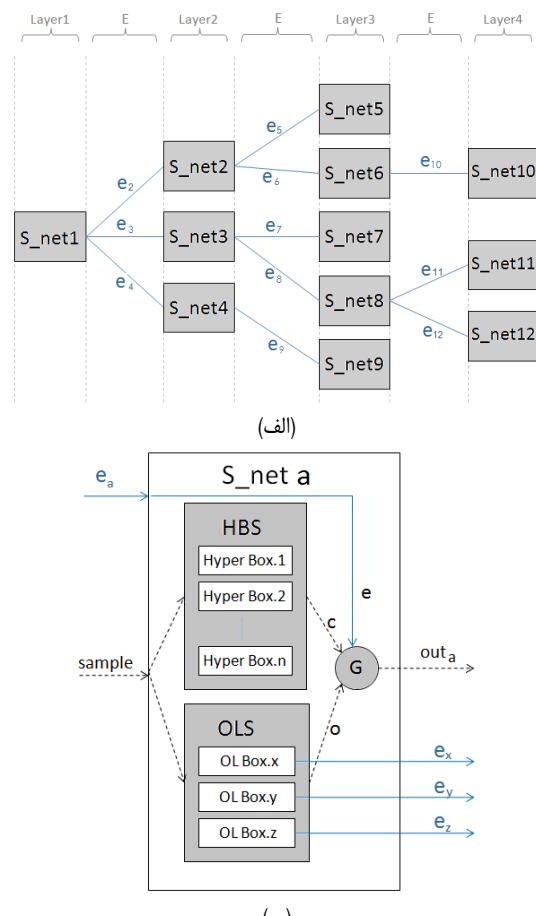
است که سادگی شبکه‌های ابتدایی FMM را نداشته و برای استفاده در سیستم‌هایی که نیاز یکی مدل ساده‌تر داریم، مانند سیستم‌های جاسازی شده و سیستم‌های Real Time مناسب نباشد. در ادامه روشی را معرفی می‌کنیم که مانند روش MLF، داده‌های موجود در نواحی همپوشان را مجددآموزش می‌دهد ولی برای اجتناب از مشکلات گفته شده از ساختار ساده‌تری بهره می‌برد.

### ۳- روش شبکه عصبی فازی مین-ماکس چندلایه وزن دار

در اینجا روش شبکه عصبی فازی مین-ماکس چندلایه وزن دار که از این پس WL-FMM نامیده می‌شود ارائه می‌گردد. در این روش بالایومن همزمان دو معیار "دقت" و "садگی ساختار" شبکه مدنظر بوده و با توجه به منطقه‌ای از فضای نمونه که کار دسته‌بندی در آن انجام می‌شود از باکس‌هایی با اندازه متفاوت و در سطوح مختلف شبکه استفاده می‌کنیم. به طوری که در نواحی غیر مرزی و یکنواخت که تنها نمونه‌های عضو یک کلاس حضور دارند، دسته‌بندی با باکس‌های بزرگ و در نواحی مرزی که نمونه‌های کلاس‌های مختلف به هم نزدیک بوده و احتمالاً در هم فورفتگی دارند، کار دسته‌بندی با استفاده از باکس‌های کوچک و با دقต بالایی انجام می‌شود. برای اجتناب از مشکلات روش MLF این کار در هر لایه فقط یک بار انجام می‌شود، به این معنی که در اینجا ساختار درختی نخواهیم داشت و همه نمونه‌های سطح آن که در ناحیه همپوشان قرار گرفته‌اند با استفاده از یک شبکه واحد که در سطح  $+1$  ام قرار دارد مدیریت می‌گردند (بازآموزی). در این روش نیز مانند سایر روش‌های FMM، همه باکس‌ها در فاز آموزش ایجاد و تنظیم شده و در فاز آزمایش از آنها استفاده می‌کنیم. همچنین هایپرباکس‌های تولیدشده در سطوح مختلف در کنار یکدیگر قرار می‌گیرند. تنها تفاوت هایپرباکس‌های نمونه‌هایی که داخل این هایپرباکس‌ها قرار می‌گیرند، (در مقایسه با هایپرباکس‌های سطوح قبلی) میزان تعليق بیشتری به کلاس‌های این هایپرباکس‌ها داشته باشند. شکل ۱۱ این مسئله را نشان می‌دهد.

### ۱-۳ ساختار شبکه

همان طور که گفته شد این شبکه از یک ساختار بسیار ساده مشابه ساختار FMM اولیه استفاده می‌کند. تنها تفاوت ساختار شبکه پیشنهادی با ساختار FMM اولیه، در وزن یال‌های بین لایه میانی و لایه پایانی است. در اینجا با اختصاص وزن بالاتر به گره‌هایی که در سطوح بعدی شبکه تشکیل می‌شوند، لایه‌های مجازی شبکه شکل می‌گیرد به طوری



شکل ۱۰: (الف) ساختار درختی شبکه MLF و (ب) ساختار داخلی یک زیرشبکه [۱۵].

توسط همین یال کنترل می‌شود. به همین ترتیب تابع آموزش زیرشبکه‌های مختلف را در لایه‌های مختلف ایجاد می‌کند. این روش دقیق‌تر نسبت به سایر شبکه‌های FMM ارائه نموده است به طوری که شبکه‌های FMM را به یک ابزار بسیار قوی در زمینه یادگیری ماشین و شناسایی الگو تبدیل کرده است، ولی علی‌رغم این نقاط مشیت، مشکلاتی را به همراه دارد که بیشتر آنها ناشی از پیچیدگی بالای ساختار این شبکه‌ها می‌شود. به طور مثال وقتی ترکیب نمونه‌ها به صورتی باشد که نمونه‌های زیادی در نواحی مرزی داشته باشیم، تعداد بسیار زیادی از باکس‌های همپوشان تولید می‌شوند که با یکدیگر همپوشانی دارند. وجود این همپوشانی‌ها باعث یادگیری چندباره نمونه‌های نمونه‌های در این نواحی می‌گردد که تأثیری در عملکرد سیستم ندارد و تنها پیچیدگی مدل را افزایش می‌دهد. از طرفی ساختار طراحی شده به گونه‌ای

لایه‌های مختلف شبکه ایجاد می‌شوند. در این روش برخلاف روش‌های پیشین، مقابله و مدیریت نواحی همپوشان هر لایه از شبکه به بعد از ایجاد و تنظیم همه باکس‌های موجود در آن شبکه موکول می‌شود.

فاز آموزش شامل دو زیربخش اصلی "ایجاد و تنظیم باکس‌ها" و "مدیریت نواحی همپوشان" است که در بخش "ایجاد و تنظیم باکس‌ها" به ازای هر یک از نمونه‌های ورودی، مرحله Extension را تکرار می‌کنیم تا باکس‌های مربوط به لایه جاری را ایجاد و تنظیم کنیم و پس از آن در بخش "مدیریت نواحی همپوشان" تمامی نواحی همپوشان موجود بین باکس‌های لایه جاری را بررسی کرده و همه نمونه‌های حاضر در این نواحی را شناسایی می‌کنیم. از نمونه شناسایی شده به عنوان نمونه‌های آموزشی لایه بعدی استفاده کرده و لایه بعدی شبکه را ایجاد می‌کنیم. نحوه ایجاد لایه بعدی دقیقاً شیوه مرحله ایجاد لایه قبلی بوده و هایپرباکس‌های ایجادشده در این لایه (با اختصاص وزن مناسب) به مجموعه هایپرباکس‌های شبکه اضافه می‌گردد.

در این روش برای کنترل حداکثر میزان بزرگی هایپرباکس‌ها از (۶) استفاده شده است. البته ذکر این نکته ضروری است که برای اطمینان از کوچکبودن باکس‌های زیرشبکه فرزند نسبت به باکس‌های والد (برای دست‌یابی به دقت بیشتر در لایه‌های بعدی)، برای تعیین حداکثر اندازه باکس‌ها در لایه فرزند از (۱۹) استفاده می‌کنیم.

فرایند یادگیری به صورت بازگشتی تا زمانی که یکی از شرایط پایان الگوریتم رخ دهد انجام می‌شود. شرایط پایان در نظر گرفته شده می‌تواند یکی از موارد زیر بوده و یا ترکیبی از آنها باشد:

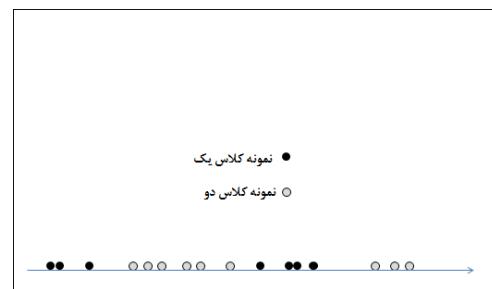
(الف) اگر تعداد نمونه‌های باقی‌مانده در ناحیه همپوشان لایه ایجادی کمتر از  $K$  باشد الگوریتم متوقف گردد ( ک یک عدد کوچک است).

(ب) اگر تعداد نمونه‌های باقی‌مانده در ناحیه همپوشان لایه ایجادی کمتر از  $P$  درصد نمونه‌های آموزشی وارد شده به لایه باشد الگوریتم متوقف شود.

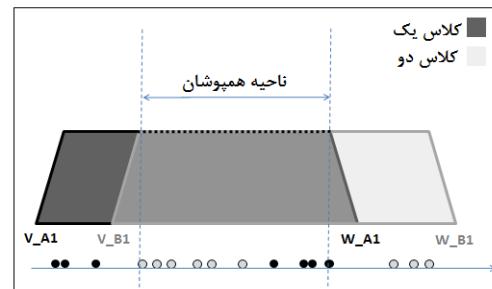
در شکل ۱۲ بلوک دیاگرام مربوط به فاز آموزش نشان داده شده است. همان طور که ملاحظه می‌شود وجود تمایز روش ارائه شده با روش MLF [۱۵] در ساختار هایپرباکس‌های مورد استفاده و همچنین نحوه مدیریت نواحی همپوشان است به این صورت که در این روش از هایپرباکس‌های وزن دار در یک ساختار خطی استفاده می‌شود. همچنین در روش ارائه شده برخلاف روش مذکور، در مورد تمامی نمونه‌هایی که در نواحی همپوشان قرار دارند به صورت یک جا تصمیم‌گیری می‌شود. بنابراین در این روش نیازی به استفاده از ساختار درختی نبوده و همه هایپرباکس‌ها در یک سطح قرار می‌گیرند، در صورتی که در روش MLF برای هر یک از نواحی همپوشان یک زیرشبکه مستقل تشکیل شده و نمونه‌های موجود در آن ناحیه، هایپرباکس‌های مربوط را ایجاد می‌نمایند. از طرف دیگر هر یک از هایپرباکس‌های مورد استفاده در روش ارائه شده، وزن به خصوص خود را دارند که باعث بهبود کارایی در بخش مدیریت نواحی همپوشان می‌گردد.

### ۳-۳ فاز آزمایش

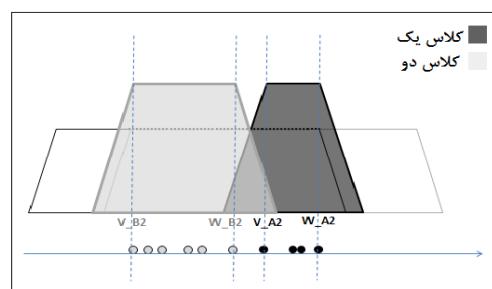
همان طور که قبلاً گفته شد در روش ارائه شده، خروجی شبکه لزوماً در لایه آخر مشخص نمی‌شود بلکه با توجه به مختصاتی از فضای نمونه که نمونه آزمایشی در آن واقع شده و همچنین با توجه محدوده تحت پوشش هایپرباکس‌های موجود در لایه‌های مختلف شبکه، بهترین لایه از شبکه برای تعیین خروجی انتخاب شده و خروجی آن به عنوان خروجی کل



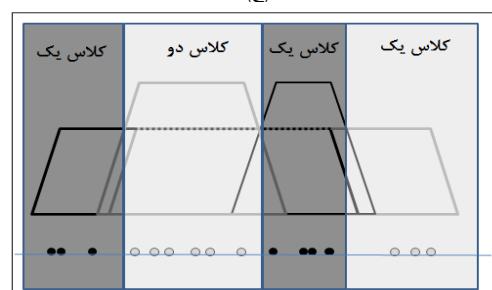
(الف)



(ب)



(ج)



(د)

شکل ۱۱: نحوه عملکرد الگوریتم ارائه شده، (الف) نمونه‌های آموزشی، (ب) دو هایپرباکس تشکیل شده در سطح اول برای دو کلاس مختلف، (ج) هایپرباکس‌های تشکیل شده در سطح دوم برای دو کلاس با وزن بیشتر و (د) نحوه کلاس‌بندی فضای نمونه.

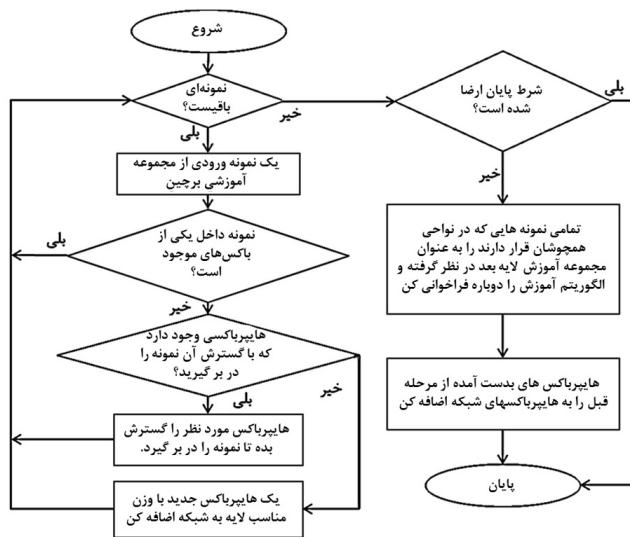
که هایپرباکس‌هایی که در لایه پایانی قرار می‌گیرند بیشترین و لایه ابتدایی شبکه کمترین وزن یال را به خود اختصاص می‌دهند. بنابراین ساختار شبکه پیشنهادی همان ساختار نشان داده شده در شکل ۲-۲ بوده و مقادیر  $U$  طبق رابطه زیر محاسبه می‌گردد

$$u_{ij} = \begin{cases} \sqrt{l}, & \text{if } (b_j^i \in C_j) \\ \cdot, & \text{if } (b_j^i \notin C_j) \end{cases} \quad (20)$$

که  $b_j^i$  نام هایپرباکس مربوط و  $l$  شماره لایه هایپرباکس است.

### ۲-۳ فاز آموزش

در فاز آموزش، ساختار شبکه شکل گرفته و زیرشبکه‌های مذکور در



شکل ۱۲: بلوك دیاگرام مربوط به فاز آموزش روش پیشنهادی.

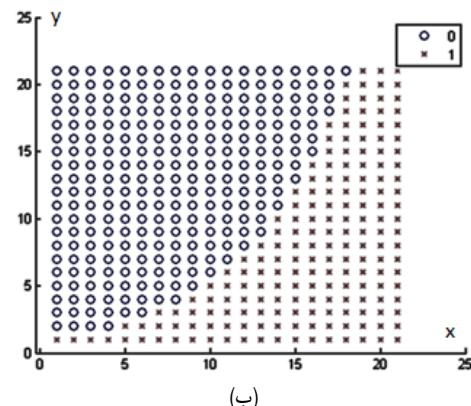
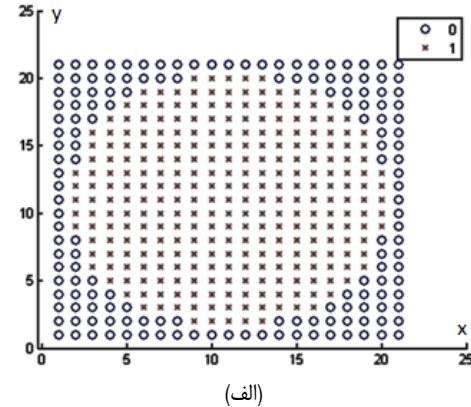
پیشنهادی (WL-FMM) می‌پردازیم که با توجه به این که کارایی بالای روش‌های FMM در مقایسه با سایر روش‌های طبقه‌بندی در منابع مختلف نشان داده شده است [۶] تا [۹] و [۱۹]، عملکرد روش پیشنهادی را تنها در مقایسه با روش‌های قبلی FMM مورد ارزیابی قرار می‌دهیم. برای انجام این بررسی از داده‌های واقعی موجود در اینترنت مانند اطمینان بیشتر از دو مجموعه داده دو بعدی (به صورت اشکال خاص) نیز استفاده شده است که شامل یک دایره به شعاع ۰/۵ و یکتابع نمایی  $e^{x/y}$  است که هر یک در یک ماتریس  $21 \times 21$  ایجاد شده و به ترتیب در شکل ۱۳-الف و ۱۳-ب نشان داده شده‌اند.

در تمام آزمایش‌های انجام‌گرفته در این تحقیق از روش ۳-fold برای آزمایش روش‌های مورد بحث استفاده شده است به طوری که داده‌های موجود به سه دسته مساوی تقسیم شده و در هر بار آزمایش یکی از دسته‌ها به عنوان داده آزمایش و مابقی داده‌ها به عنوان داده‌های آموزش استفاده شده‌اند. برای مقایسه کارایی آنها از پارامترهایی مانند "میزان خطای طبقه‌بندی"، "تعداد هایپریاکس تولیدشده" و "زمان اجرا" بهره گرفته شده است. هر یک از پارامترهای مذکور به ازای بازه صفر تا یک از ضریب گسترش هایپریاکس‌ها ( $\theta$ ) مورد ارزیابی قرار گرفته و نتایج هر یک به همراه توضیحات مکفی در بخش‌های مربوطه آمده است و در پایان این بخش نیز نتایج کلی آزمایش‌ها را خواهیم دید.

الگوریتم MLF نسبت به سایر روش‌هایی که قبلاً در این حوزه ارائه شده‌اند از کارایی بالاتری برخوردار است [۱۵] و با توجه به اصلاحاتی که در روش ارائه شده (WL-FMM) نسبت به روش MLF داده شده است، انتظار داریم روش ارائه شده از نظر پیچیدگی زمانی و محاسباتی از عملکرد بهتری برخوردار باشد.

#### ۴-۱ میزان خطای طبقه‌بندی

خطای طبقه‌بندی همواره یکی از مهم‌ترین پارامترهای مقایسه کارایی روش‌های طبقه‌بندی بوده است. در این قسمت میزان خطای طبقه‌بندی روش‌های مختلف FMM مورد بررسی قرار گرفته و بخشی از نتایج



شکل ۱۳: (الف) داده‌های ایجادشده با استفاده از رابطه دایره و (ب) داده‌های ایجادشده با استفاده از یک رابطه نمایی.

شبکه در نظر گرفته می‌شود. بنابراین میزان خروجی مربوط به هر کلاس طبق رابطه زیر محاسبه می‌گردد

$$C_k = \bigcup_{j=1 \dots m} b_j u_{jk} \quad (21)$$

که در آن  $u_{jk}$  وزن یال متصل‌کننده هایپریاکس ز به گره پایانی  $k$  بوده و  $b_j$  معادل مقدار تابع عضویت هایپریاکس ز است.

#### ۴- نتایج آزمایشی

در این قسمت به بررسی نتایج به دست آمده از پیاده‌سازی روش

ساختاری بسیار متفاوت استفاده می‌کند ولی برای مدیریت نواحی همپوشان از رویدای مشابه با روش MLF (البته با تعداد هایپرباکس‌های کمتر) استفاده می‌نماید. بنابراین چنانچه ملاحظه می‌شود تفاوت زیادی از نظر دقت طبقه‌بندی، بین روش ارائه شده و روش MLF وجود ندارد ولی در مواردی مانند آنچه در مورد مجموعه داده دایره مشاهده می‌شود به دلیل نوع پراکندگی نمونه‌های این مجموعه روش MLF جواب بهتری ارائه داده است به طوری که روش ارائه شده به دلیل استفاده از هایپرباکس‌های وزن دار و دقیق در نواحی مرزی، از خطاهای کمتری در این نواحی برخوردار بوده و در مجموعه داده‌هایی که نواحی مرزی گستردۀ‌تری دارند از عملکرد بهتری برخوردار است.

#### ۴-۲ تعداد هایپرباکس تولیدشده

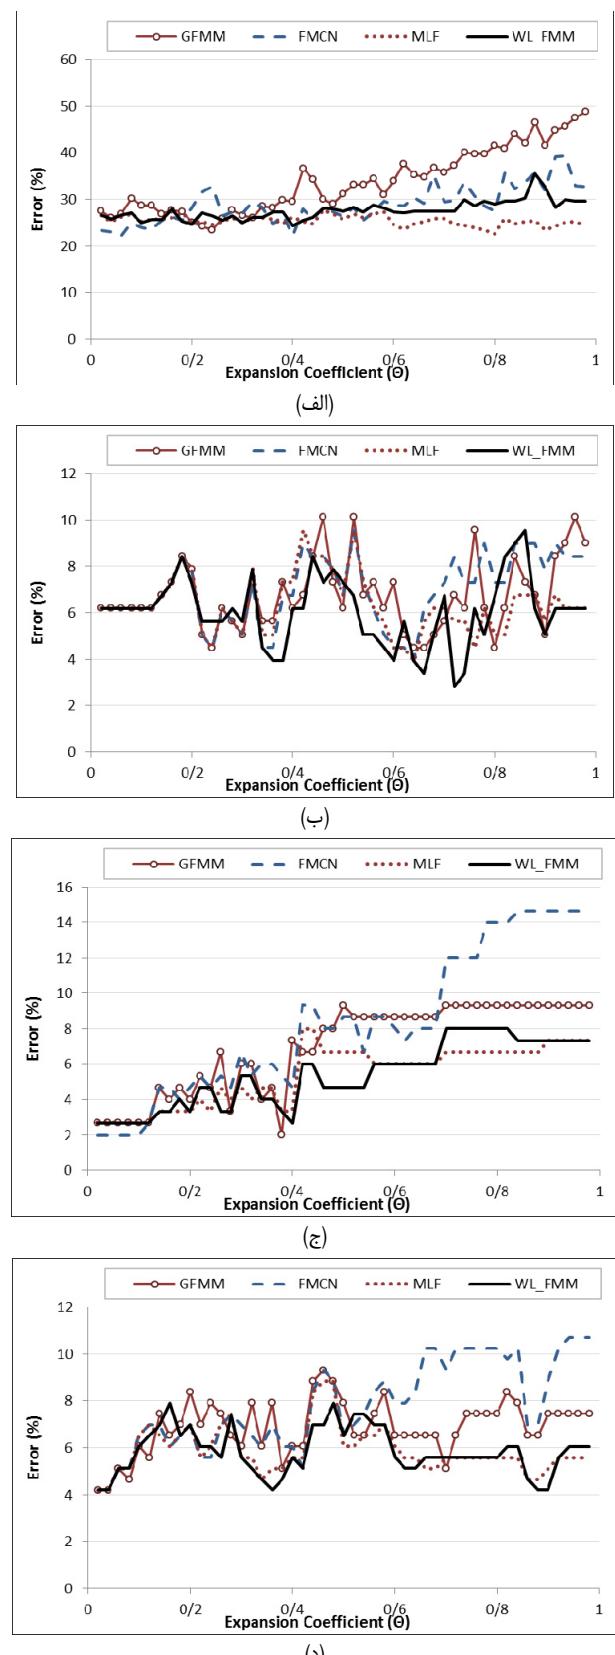
در روش‌های مورد بحث برای محاسبه پیچیدگی مکانی می‌توان از تعداد باکس‌ها (هایپرباکس‌های و گره‌های تولیدشده) استفاده کرد. این باکس‌ها و گره‌ها طی فرایند آموزش تولید شده و در فاز آزمایش مورد استفاده قرار می‌گیرند، بنابراین این باکس‌ها ذخیره شده و هزینه مکانی به همراه خواهد داشت.

با توجه به این که روش ارائه شده در مناطق مرزی از هایپرباکس‌های کوچک استفاده می‌کند، برای پوشش دادن این نواحی از تعداد زیادی هایپرباکس استفاده می‌شود و بنابراین در این روش، تعداد هایپرباکس تولیدشده به میزان مناطق مرزی موجود در فضای نمونه بستگی خواهد داشت. در شکل ۱۵ نمودارهای مربوط به تعداد باکس‌های تولیدشده توسط هر یک از الگوریتم‌های مورد مقایسه را مشاهده می‌کنید. در آزمایش‌های این قسمت و آزمایش‌های بعدی این نوشتۀ، از ۵۰ درصد نمونه‌ها که به صورت تصادفی انتخاب شده‌اند برای آموزش شبکه‌ها و از مابقی نمونه‌ها برای آزمایش آنها استفاده شده است.

همان طور که مشاهده می‌شود تعداد هایپرباکس تولیدشده در روش پیشنهادی برای مجموعه داده‌های Iris, Wine و Thyroid بسیار پایین بوده و در حد تعداد هایپرباکس‌های تولیدشده در روش FMM بوده است. ولی در مجموعه داده تابع نمایی که به صورت مصنوعی ایجاد شده، به دلیل نسبت بالای تعداد نمونه‌های آموزشی به تعداد ابعاد، سطح وسیعی از مناطق مرزی بین دو کلاس ایجاد گردیده و از هایپرباکس‌های زیادی برای انجام طبقه‌بندی استفاده شده است. دلیل دیگر این امر تعداد زیاد نمونه‌های آموزشی و همچنین حالت مورب تابع نمایی است که با ساختار هایپرباکس‌ها (که به صورت مستطیل‌های موازی محورها هستند) همخوانی نداشته و باعث تولید نواحی همپوشان زیادی می‌شود. این حالت در روش MLF شدیدتر است زیرا در این حالت، احتمال ایجاد همپوشانی بین نواحی همپوشانی تعریف شده، بالا رفته و در نتیجه همان طور که در شکل ۱۵ مشاهده می‌شود، هایپرباکس‌های زیادی در لایه‌های بعد برای پوشش این نواحی ایجاد می‌نماید.

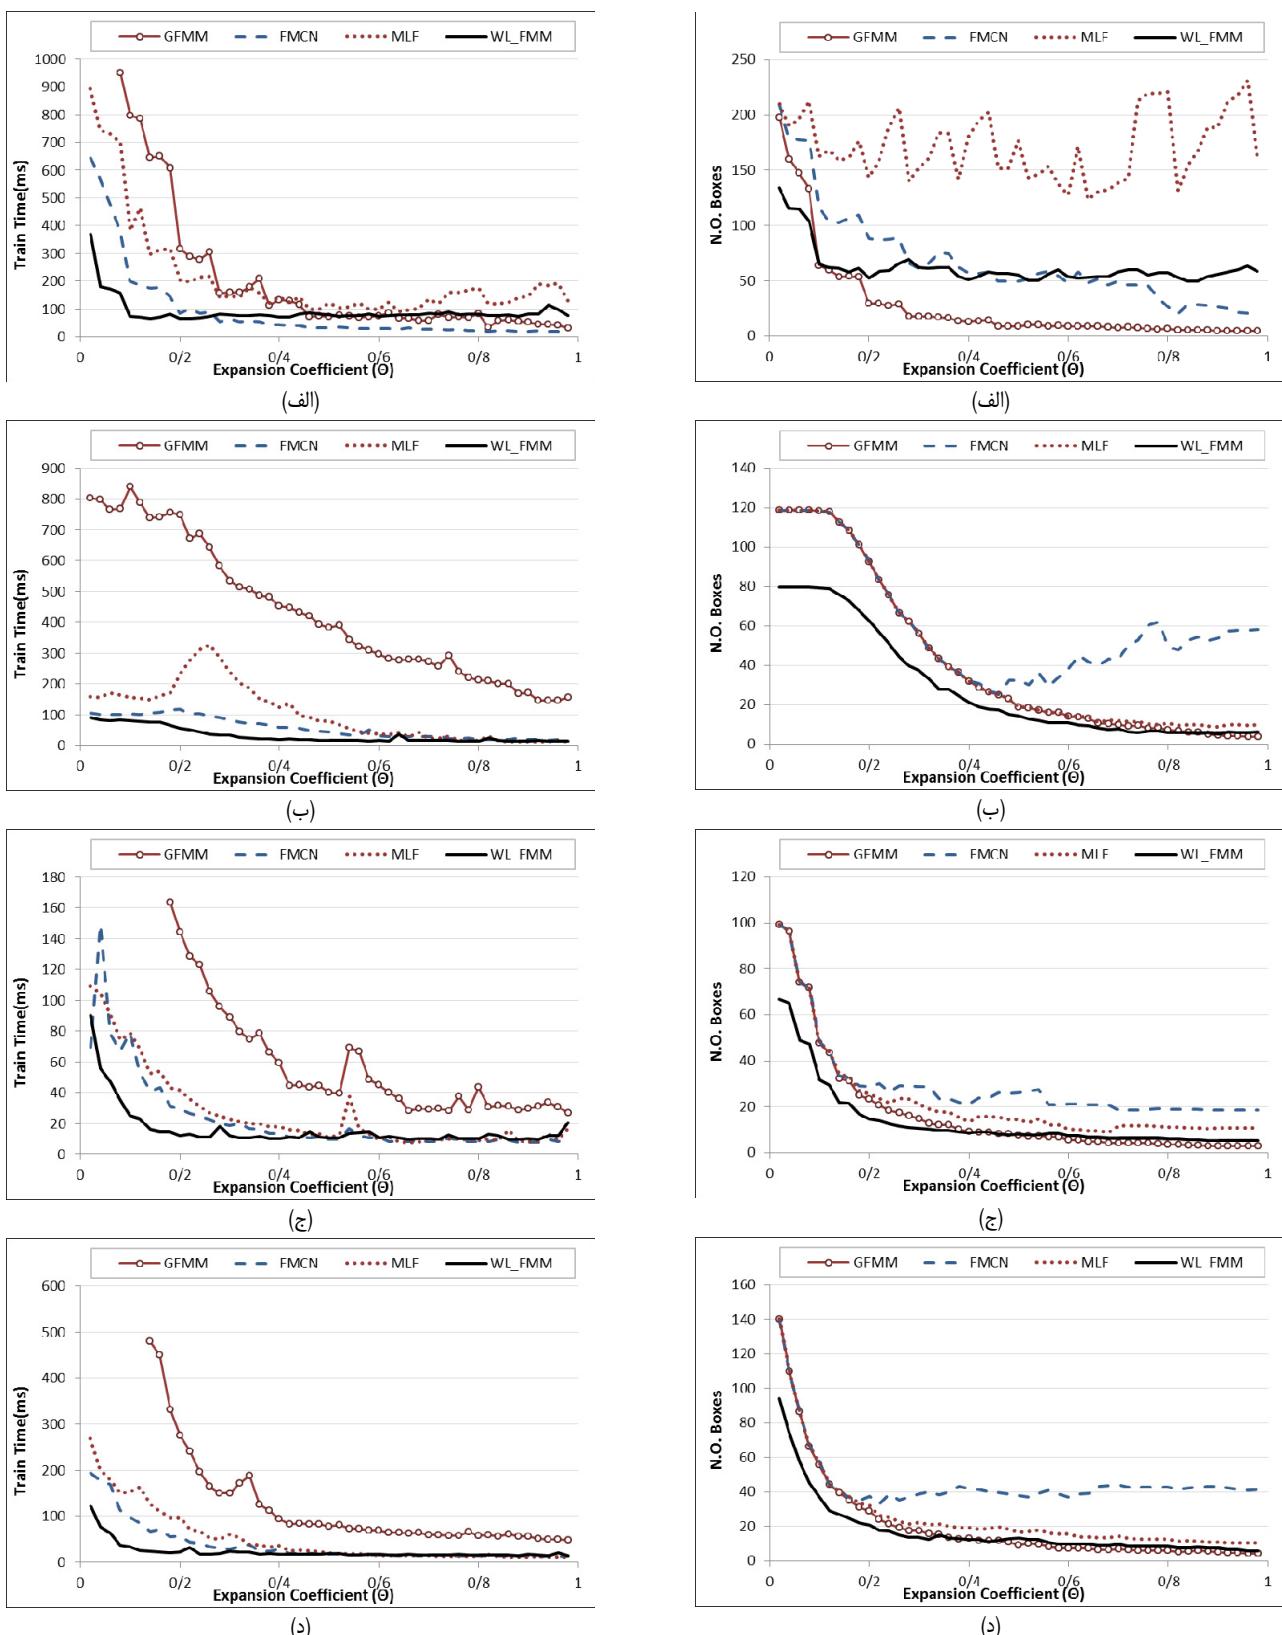
#### ۴-۳ زمان اجرا

با توجه به این که طبقه‌بندهایی که بر اساس FMM کار می‌کنند تک‌گذار هستند، در مقایسه با سایر روش‌های طبقه‌بندی از زمان اجرای بسیار کمی برخوردارند، به طوری که برای انجام کارهای بلاذرنگ<sup>۱</sup> بسیار مناسب هستند. در اینجا زمان‌های به دست آمده از اجزای فاز یادگیری در شکل ۱۶ آمده است. این نمودارها از اجرای الگوریتم‌های مورد بحث



شکل ۱۴: نمودارهای مقایسه خطای طبقه‌بندی برای مجموعه داده‌ای (الف) Exponential، (ب) Iris، (ج) Wine و (د) Thyroid.

حاصل به ازای  $\theta$  های مختلف و برای روش‌های بحث شده در نمودارهای نشان داده شده در شکل ۱۴-الف تا شکل ۱۴-د آمده است. در این شکل‌ها نتایج حاصل از اجرای روش‌های فوق روی داده‌های Iris, Thyroid, Wine و رابطه نمایی ایجاد شده (شکل ۱۳-ب) را می‌بینید. همان طور که قبلاً اشاره شد، روش ارائه شده نسبت به روش MLF از



شکل ۱۶: نمودارهای مقایسه زمان یادگیری برای مجموعه داده‌های (الف) Thyroid (ج) (د) Exponential (ب) Iris (ج) (د) Circle (ب) (ج) (د)

در این قسمت نتایج کلی به دست آمده از اجرای روش‌های مورد بحث بر روی داده‌های Thyroid, Cancer, Breast, Glass, Wine, Iris و مجموعه داده ایجادشده را در قالب جدول ۱ مشاهده می‌کنید که در

بر روی کامپیوتری با پردازنده  $1/3$  MHz core2 و با حافظه اصلی ۴ GB به دست آمده است.

همان طور که در شکل ۱۶ مشاهده می‌شود روش ارائه شده علی‌رغم داشتن دقت خوب در طبقه‌بندی، در بین روش‌های مقایسه شده، زمان اجرای پایین‌تری نسبت به سایر روش‌ها داشته و در مواردی بسیاری در بین این روش‌ها کمترین مدت زمان اجرا را ارائه داده است.

جدول ۱: مقایسه کارایی روش ارائه شده و روش‌های مختلف FMM بر روی داده‌های مختلف.

| Data Set                        | Method | Miss classification (%) |       |         | Number of boxes (Average) | Time (ms) (Average) |
|---------------------------------|--------|-------------------------|-------|---------|---------------------------|---------------------|
|                                 |        | Max                     | Min   | Average |                           |                     |
| Iris                            | GFMM   | ۹,۳۳                    | ۲,۰۰  | ۶,۹۴    | ۱۶,۵۰                     | ۵۴,۲۹               |
|                                 | FMCN   | ۶۷,۱۴                   | ۲,۰۰  | ۸,۳۱    | ۲۸,۴۴                     | ۲۱,۹۵               |
|                                 | MLF    | ۸,۰۰                    | ۲,۶۷  | ۵,۴۰    | ۲۱,۷۰                     | ۲۵,۷۱               |
| Breast Cancer                   | WL-FMM | ۸,۰۰                    | ۲,۶۷  | ۵,۳۶    | ۱۳,۱۸                     | ۱۵,۶۳               |
|                                 | GFMM   | ۱۰,۹۸                   | ۳,۶۶  | ۵,۷۷    | ۱۰,۴,۰۷                   | ۵۳۴,۱,۰۷            |
|                                 | FMCN   | ۶,۸۸                    | ۴,۲۵  | ۵,۰۸    | ۱۳۷,۷۰                    | ۳۳۱,۶۶              |
| Wine                            | MLF    | ۵,۵۶                    | ۲,۹۳  | ۴,۳۱    | ۱۲۲,۱۴                    | ۵۷۳,۳۷              |
|                                 | WL-FMM | ۵,۶۲                    | ۳,۸۱  | ۴,۵۳    | ۷۵,۸۰                     | ۱۶۵,۶۷              |
|                                 | GFMM   | ۱۰,۱۱                   | ۴,۴۹  | ۶,۷۴    | ۳۹,۶۷                     | ۴۱۸,۱۸              |
| Glass                           | FMCN   | ۹,۰۰                    | ۳,۹۳  | ۶,۹۶    | ۵۹,۳۶                     | ۵۳,۸۳               |
|                                 | MLF    | ۹,۰۰                    | ۳,۹۳  | ۶,۳۳    | ۴۰,۹۷                     | ۹۹,۰۴               |
|                                 | WL-FMM | ۹,۰۰                    | ۲,۸۱  | ۶,۰۴    | ۲۷,۳۸                     | ۳۰,۷۱               |
| Ionosphere                      | GFMM   | ۵۵,۶۱                   | ۳۲,۲۴ | ۴۶,۵۸   | ۳۱,۳۳                     | ۲۸۴,۳۸              |
|                                 | FMCN   | ۷۰,۵۶                   | ۳۳,۱۸ | ۵۳,۴۶   | ۱۲۰,۲۲                    | ۴۸,۲۳               |
|                                 | MLF    | ۴۶,۲۶                   | ۳۰,۳۷ | ۳۸,۲۵   | ۷۴,۷۷                     | ۱۰۳,۹۶              |
| Thyroid                         | WL-FMM | ۴۵,۷۹                   | ۳۲,۲۴ | ۳۷,۷۱   | ۳۰,۶۳                     | ۳۵,۱۷               |
|                                 | GFMM   | ۶۴,۶۷                   | ۳۵,۹۰ | ۴۷,۹۲   | ۹۸,۲۸                     | ۱۶۷۸,۷۷             |
|                                 | FMCN   | ۲۰,۲۳                   | ۱۳,۳۹ | ۱۵,۸۴   | ۲۰,۳,۶۳                   | ۳۱,۰,۹۷             |
| Circle<br>$(x^r + y^r < 9,5^r)$ | MLF    | ۱۹,۹۴                   | ۱۱,۶۸ | ۱۴,۹۰   | ۱۰,۳,۸۲                   | ۳۶۵,۴۳              |
|                                 | WL-FMM | ۳۰,۷۷                   | ۱۱,۶۸ | ۱۷,۰۴   | ۶۴,۹۹                     | ۱۲۶,۵۲              |
|                                 | GFMM   | ۹,۳۰                    | ۴,۱۹  | ۶,۸۸    | ۲۰,۰,۰۸                   | ۱۱۲,۰۱              |
| Exponential<br>$(y^x < e^x)$    | FMCN   | ۱۰,۷۰                   | ۴,۱۹  | ۷,۸۱    | ۴۴,۶۶                     | ۳۶,۴۳               |
|                                 | MLF    | ۸,۸۴                    | ۴,۱۹  | ۵,۸۹    | ۲۵,۲۰                     | ۴۹,۱۵               |
|                                 | WL-FMM | ۷,۹۱                    | ۴,۱۹  | ۵,۸۴    | ۱۶,۷۳                     | ۲۲,۳۵               |
| Circle<br>$(x^r + y^r < 9,5^r)$ | GFMM   | ۳۶,۹۸                   | ۲۳,۷۶ | ۳۰,۱۶   | ۲۷,۲۰                     | ۱۸۰,۳۰              |
|                                 | FMCN   | ۴۰,۵۰                   | ۲۳,۱۴ | ۳۲,۴۵   | ۶۶,۶۲                     | ۹۱,۴۴               |
|                                 | MLF    | ۲۸,۳۱                   | ۱۹,۲۱ | ۲۲,۳۷   | ۱۷۴,۲۴                    | ۲۲۰,۸۱              |
| Exponential<br>$(y^x < e^x)$    | WL-FMM | ۳۸,۲۲                   | ۲۷,۸۹ | ۳۲,۴۸   | ۶۳,۴۴                     | ۸۰,۶۷               |
|                                 | GFMM   | ۴۰,۲۹                   | ۲۵,۰۰ | ۳۲,۹۴   | ۲۷,۰,۰۷                   | ۳۴۶,۰,۰۷            |
|                                 | FMCN   | ۳۹,۰۵                   | ۲۲,۷۳ | ۳۲,۳۰   | ۶۴,۱۹                     | ۸۹,۸۱               |
| Exponential<br>$(y^x < e^x)$    | MLF    | ۲۹,۷۵                   | ۱۹,۴۲ | ۲۴,۱۱   | ۱۶۸,۳۳                    | ۲۰۸,۰۱              |
|                                 | WL-FMM | ۳۵,۵۴                   | ۲۵,۰۰ | ۳۱,۳۲   | ۶۱,۰۲                     | ۸۷,۲۱               |

قبلی شبکه‌های FMM ارائه شده با این تفاوت که از ساختار ساده‌تری استفاده کرده و با استفاده از وزن دهنده به یال خروجی هایپرباکس‌ها، رویکرد مناسبی برای مدیریت نواحی همپوشان در پیش می‌گیرد. تغییرات انجام‌گرفته به نحوی است که ضمن داشتن دقت بالا در طبقه‌بندی، در مدت زمان کوتاه‌تری نمونه‌ها را آموزش داده و پیچیدگی ساختاری روش‌های قبلی را ندارد.

نتایج به دست آمده از پیاده‌سازی این روش و مقایسه آن با سایر روش‌های FMM حاکی از کاهش محسوس زمان یادگیری و میزان حافظه مصرف شده برای ذخیره مدل است. ضمن این که روش ارائه شده در طبقه‌بندی مجموعه داده‌های طبیعی از دقت بسیار خوبی برخوردار بوده و در اکثر موارد در بین روش‌های مورد بحث بهترین عملکرد را داشته است.

با توجه به کارایی بالای روش پیشنهادی می‌توان از این نوع شبکه‌ها در اکثر کاربردهای یادگیری ماشین بهره جست. به خصوص این که با توجه به سرعت بالای این روش می‌توان از آن در سیستم‌های بلاذرنگ استفاده نمود. همچنین به دلیل حجم کم و دقت مناسب این شبکه‌ها

هر قسمت بهترین جواب به دست آمده به صورت پرنگ<sup>۱</sup> مشخص شده است.

همان طور که مشاهده می‌شود روش ارائه شده در بین روش‌های مورد بررسی و در تمامی آزمایش‌های انجام‌شده دارای بهترین زمان یادگیری و کمترین تعداد هایپرباکس‌هاست. ضمن این که در اکثر قریب به اتفاق موارد، دقت روش ارائه در بیش از سایر روش‌ها بوده یا حداقل هم‌طراز با روش MLF است (به خصوص در مورد مجموعه داده‌های اخذشده از [۳۲] که نمونه‌های آنها از طبیعت جمع‌آوری شده‌اند). بنابراین روش ارائه شده ضمن کاهش پیچیدگی شبکه نسبت به روش‌های مشابه از دقت بالایی برخوردار است.

## ۵- نتیجه‌گیری

در این مقاله روش شبکه عصبی فازی مین-ماکس چندسطحی با باکس‌های وزن دار (WL-FMM) ارائه شد. این روش بر پایه روش‌های

1. Bold

- [24] J. Hu, J. Yang, and J. Gao, "Ordination-fuzzy min-max neural network classifier on unlabelled pattern classification," *Moshi Shiebie yu Rengong Zhineng/Pattern Recognition and Artificial Intelligence*, vol. 20, no. 2, pp. 173-179, Feb. 2007.
- [25] J. Yang, J. Gao, X. H. Xu, and X. Liu, "Hierarchical fuzzy min-max clustering algorithm," *Moshi Shiebie yu Rengong Zhineng/Pattern Recognition and Artificial Intelligence*, vol. 20, no. 4, pp. 558-564, Apr. 2007.
- [26] A. Quteishat and C. P. Lim, "A modified fuzzy min-max neural network with rule extraction and its application to fault detection and classification," *Applied Soft Computing J.*, vol. 8, no. 2, pp. 985-995, Mar. 2008.
- [27] R. Zemouri, D. Racoceanu, N. Zerhouni, E. Minca, and F. Filip, "Training the recurrent neural network by the fuzzy min-max algorithm for fault prediction," in *Proc. 2nd Mediterranean Conference on Intelligent Systems and Automation. CISA'09*, pp. 85-90, Zarzis, Tunisia, 23-25 Mar. 2009.
- [28] X. Ge and E. J. Ding, "Research on parameters of fuzzy min-max neural networks," *Kongzhi yu Juece/Control and Decision*, vol. 25, no. 8, pp. 295-298, Aug. 2010.
- [29] A. Quteishat, C. P. Lim, and K. S. Tan, "A modified fuzzy min-max neural network with a genetic-algorithm-based rule extractor for pattern classification," *IEEE Trans. on Systems, Man, and Cybernetics Part A: Systems and Humans*, vol. 40, no. 3, pp. 641-650, May 2010.
- [30] P. Rey-del-Castillo and J. Cardenosa, "Fuzzy min-max neural networks for categorical data: application to missing data imputation," *Neural Computing and Applications*, vol. 21, no. 6, pp. 1349-1362, Sep. 2012.
- [31] R. Davtalab, M. Parchami, M. H. Dezfoolian, M. Mansoorizadeh, and B. Akhtar, "M-FMCN: modified fuzzy min-max classifier using compensatory neurons," in *the Proc. of the 11th WSEAS International Conf. on Artificial Intelligence, Knowledge Engineering and Data Bases, Cambridge, UK*, pp. 77-82, Feb. 2012.
- [32] C. Blake, E. Keogh, and C. Merz, *UCI Repository of Machine Learning Databases*, Irvine: Department of Information and Computer Science, University of California, 1998.

**رضا داوطلب** در سال ۱۳۸۶ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه آزاد شیست و در سال ۱۳۹۰ مدرک کارشناسی ارشد مهندسی کامپیوتر خود را از دانشگاه بولی عین همدان دریافت نمود. پس از آن برای ادامه تحصیل در قطعه دکتری، در سال ۱۳۹۳ به عنوان سهمیه استعداد درخشان وارد دانشگاه تبریز شده و مشغول به تحصیل در این دوره است. نامبرده از سال ۱۳۹۴ تا ۱۳۹۵ نیز سایه همکاری با مرکز تحقیقات مخابرات به عنوان عضو تیم فنی طرح جویشگر بومی را دارد. زمینه های علمی مورد علاقه ایشان موضوعاتی مانند شناسایی آماری الگو، شبکه های فازی مین-ماکس، سیستم های فازی و الگوریتم ها تکاملی است.

**محمدعلی بالافر** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد در رشته مهندسی کامپیوتر به ترتیب در سال ۱۳۷۶ و ۱۳۸۰ در دانشگاه های اصفهان و تربیت مدرس به پایان رسانده و در سال ۱۳۹۰ مدرک دکتری خود را از دانشگاه یو پی ام مالزی در رشته فناوری اطلاعات و چندرسانه ای دریافت نموده است. دکتر بالافر هم اکنون استادیار گروه فناوری اطلاعات دانشگاه تبریز بوده و از سوابق علمی و اجرایی ایشان می توان به مدیریت گروه مهندسی فناوری اطلاعات از سال ۱۳۹۱ تا کنون اشاره نمود. از زمینه های کاری مورد علاقه ایشان می توان پردازش تصاویر پر شکی، داده کاوی، الگوریتم های بهینه سازی تکاملی، شبکه های عصبی و سیستم های فازی را نام برد.

**محمد رضا فیضی** درخشی در سال ۱۳۷۶ مدرک کارشناسی خود از دانشگاه اصفهان و در سال های ۱۳۷۹ و ۱۳۸۶ به ترتیب مدارک کارشناسی ارشد و دکتری خود را در رشته مهندسی کامپیوتر از دانشگاه علم صنعت ایران دریافت نمود. دکتر فیضی هم اکنون با درجه داشتیاری عضو هیأت علمی گروه مهندسی کامپیوتر دانشگاه تبریز بوده و از جمله سوابق علمی و اجزایی ایشان می توان به مدیریت گروه کامپیوتر دانشگاه تبریز از سال ۱۳۸۶ تا ۱۳۸۷ و مدیریت مرکز آموزش های آزاد و مجازی همان دانشگاه در سال های ۱۳۸۷ تا ۱۳۹۲ اشاره نمود. زمینه های کاری مورد علاقه ایشان الگوریتم های هوشمند بهینه سازی، پردازش زبان طبیعی، خلاصه سازی متن و گفتار، پایگاه داده های هوشمند و دسته بندی صفحات وب است.

می توان از آنها در سیستم های سخت افزاری و یا سیستم هایی که با حجم بالایی از داده ها مواجه هستند، استفاده نمود.

## مراجع

- [1] L. A. Zadeh, "Fuzzy Sets," *Inform. and Control*, vol. 8, pp. 189-200, 1965.
- [2] J. C. Bezdek, S. K. Pal, and IEEE Neural Networks Council., *Fuzzy models for pattern recognition: methods that search for structures in data*, New York: Institute of Electrical and Electronics Engineers, 1992.
- [3] J. Vieira, F. M. Dias, and A. Mota, *Neuro-Fuzzy Systems: A Survey*, 2004.
- [4] S. Mitra and Y. Hayashi, "Neuro-fuzzy rule generation: survey in soft computing framework," *Neural Networks, IEEE Trans. on*, vol. 11, no. 3, pp. 748-768, May 2000.
- [5] D. Nauck and R. Kruse, *What Are Neuro-Fuzzy Classifiers?*, 1997.
- [6] A. Bargiela, W. Pedrycz, and M. Tanaka, "An inclusion/exclusion fuzzy hyperbox classifier," *International J. of Knowledge Based Intelligent Engineering Systems*, vol. 8, no. 2, pp. 91-98, Aug. 2004.
- [7] B. Gabrys and A. Bargiela, "General fuzzy min-max neural network for clustering and classification," *IEEE Trans. on Neural Networks*, vol. 11, no. 3, pp. 769-783, May 2000.
- [8] A. V. Nandedkar and P. K. Biswas, "A fuzzy min-max neural network classifier with compensatory neuron architecture," *IEEE Trans. on Neural Networks*, vol. 18, no. 1, pp. 42-54, Jan. 2007.
- [9] P. K. Simpson, "Fuzzy min-max neural networks I: classification," *IEEE Trans. on Neural Networks*, vol. 3, no. 5, pp. 776-786, Sep. 1992.
- [10] A. Joshi, N. Ramakrishnan, E. N. Houstis, and J. R. Rice, "On neurobiological, neuro-fuzzy, machine learning, and statistical pattern recognition techniques," *IEEE Trans. on Neural Networks*, vol. 8, no. 1, pp. 18-31, Jan. 1997.
- [11] P. K. Simpson, "Fuzzy min-max neural networks, part 2, clustering," *IEEE Trans. on Fuzzy Systems*, vol. 1, no. 1, pp. 32-45, Feb. 1993.
- [12] A. V. Nandedkar and P. K. Biswas, "A reflex fuzzy min max neural network for semi-supervised learning," *J. of Intelligent Systems*, vol. 17, no. 1, pp. 5-18, Aug. 2008.
- [13] A. V. Nandedkar and P. K. Biswas, "A granular reflex fuzzy min-max neural network for classification," *IEEE Trans. on Neural Networks*, vol. 20, no. 7, pp. 1117-1134, Jul. 2009.
- [14] H. Zhang, J. Liu, D. Ma, and Z. Wang, "Data-core-based fuzzy min-max neural network for pattern classification," *IEEE Trans. on Neural Networks*, vol. 22, no. 12, pp. 2339-2352, Nov. 2011.
- [15] R. Davtalab, M. H. Dezfoolian, and M. Mansoorizadeh, "Multi-level fuzzy min-max neural network classifier," *IEEE Trans. Neural Netw. Learn Syst*, vol. 25, no. 3, pp. 470-482, Mar. 2014.
- [16] Q. Hua, "A new union-set learning algorithm in fuzzy min-max neural networks," *Moshi Shiebie yu Rengong Zhineng/Pattern Recognition and Artificial Intelligence*, vol. 14, no. 4, p. 413, 2001.
- [17] B. Gabrys, "Agglomerative learning algorithms for general fuzzy min-max neural network," *J. of VLSI Signal Processing Systems for Signal, Image, and Video Technology*, vol. 32, no. 1, pp. 67-82, Aug. 2002.
- [18] A. V. Nandedkar and P. K. Biswas, "A general fuzzy min max neural network with compensatory neuron architecture," in *Proc. Int. Conf. on Knowledge-Based and Intelligent Information and Engineering Systems*, pp. 1160-1167, 2005.
- [19] P. F. Peng, L. J. Yang, and Q. G. Zhang, "Improvement and application based on general fuzzy min-max neural network," *Wuhan Ligong Daxue Xuebao/J. of Wuhan University of Technology*, vol. 26, no. 10, p. 87, Oct. 2004.
- [20] P. F. Peng, L. J. Yang, and Q. G. Zhang, "Unsupervised general fuzzy min-max artificial neural network," *Xi Tong Gong Cheng Yu Dian Zi Ji Shu/Systems Engineering and Electronics*, vol. 26, no. 10, pp. 1503-1505+1536, Oct. 2004.
- [21] G. Tang, Y. Dai, and G. Liu, "Radar range profile classification based on fuzzy min-max neural networks," *Binggong Xuebao/Acta Armamentarii*, vol. 25, no. 2, pp. 218-221, Feb. 2004.
- [22] H. J. Kim and H. S. Yang, "A weighted fuzzy min-max neural network and its application to feature analysis," in *Proc. of the First Int. Conf. on Advances in Natural Computation*, vol. 3, pp. 1178-1181, Changsha, China 27-29 Aug. 2005.
- [23] C. C. Chen, "Design of a fuzzy min-max hyperbox classifier using a supervised learning method," *Cybernetics and Systems*, vol. 37, pp. 329-346, 2006.