

# استفاده از یادگیری همبستگی منفی در بهبود کارایی ترکیب شبکه‌های عصبی

علی کارگر نژاد<sup>۱</sup>، سعید مسعودنیا<sup>۲</sup> و امیرحسین کاشفی<sup>۳</sup>

<sup>۱</sup>دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران.

<sup>۲</sup>دانشگاه آزاد اسلامی، واحد تهران مرکز و باشگاه پژوهشگران جوان، تهران، ایران.

<sup>۳</sup>دانشگاه آزاد اسلامی، واحد تهران جنوب، باشگاه پژوهشگران جوان، تهران، ایران.

## چکیده

یکی از روش‌های بهبود صحبت طبقه‌بندی داده‌ها، استفاده از چند طبقه‌بند مختلف و سپس ترکیب نتایج خروجی آنهاست که اغلب تحت عنوان ترکیب طبقه‌بندها خوانده می‌شود. پارامترهای مختلفی بر کارایی سیستم ترکیب طبقه‌بندها تأثیر می‌گذارند که از آن جمله می‌توان به میزان گوناگونی بین طبقه‌بندهای پایه سیستم اشاره کرد. در این مقاله تأثیر ایجاد گوناگونی حاصل از یادگیری همبستگی منفی را در دو روش ترکیبی کلیšeه تصمیم و تعیین انبارهای مورد بررسی قرار داده‌ایم. استفاده از یادگیری همبستگی منفی برای ایجاد گوناگونی در طبقه‌بندهای پایه سیستم ترکیبی، صحبت طبقه‌بندی را در هر دو روش مورد آزمون بهبود داده است. ایده پیشنهادی مقاله از نقطه‌نظر دیگری هم قابل ارائه است؛ نتایج این تحقیق نشان داد که کلیšeه تصمیم و تعیین انبارهای نسبت به روش‌های دیگر، روش‌های کاراتری برای ترکیب شبکه‌های حاصل از یادگیری همبستگی منفی هستند.

وازگان کلیدی: ترکیب طبقه‌بندهای عصبی، یادگیری همبستگی منفی، گوناگونی، کلیšeه تصمیم و تعیین انبارهای.

(Kuncheva, 2004). یکی از پارامترهای مؤثر در بخش اول سیستم ترکیبی، ایجاد گوناگونی<sup>۳</sup> بین طبقه‌بندهای پایه Cunningham and Chandra and Yao, 2004 است (Carney, 2000). اهمیت این پارامتر به حدی است که اگر طبقه‌بندهای پایه، مشابه باشند، هیچ بهبودی در کارایی چرخه ترکیب بدست نخواهد آمد (Tsymbal, et al., 2005). منظور از ایجاد گوناگونی بین طبقه‌بندها این است که راه کارهایی اتخاذ شود تا طبقه‌بندهای پایه خطاهای متفاوتی داشته باشند؛ به این معنی که نمونه‌هایی از ورودی که یک طبقه‌بند در مورد آنها با خطأ، تصمیم‌گیری می‌کند با خطاهای طبقه‌بندهای پایه دیگر مشابه نباشد. از این روش طور دقیق‌تر به این پارامتر گوناگونی در خطأ<sup>۴</sup> گفته می‌شود (Brown, 2004, Brown, et al., 2005).

در بخش دوم سیستم ترکیبی، قواعد و روش‌های متنوعی برای ترکیب خروجی طبقه‌بندهای پایه پیشنهاد

## ۱- مقدمه

سیستم‌های ترکیب طبقه‌بندها<sup>۱</sup> یکی از چهار مسیر پیشگام Dietterich, 1997 در حوزه یادگیری ماشین می‌باشد (Dietterich, 1997). در حقیقت استفاده از سیستم‌های سورایی<sup>۲</sup> از طبیعت انسان در استفاده از نظرات مختلف برای تصمیم‌گیری‌های مهم الهام گرفته است. نظر افراد مختلف وزن داده شده و سپس ترکیب می‌شوند تا به نتیجه نهایی حاصل شود (Polikar, 2006). بهبود کارایی حاصل از ترکیب طبقه‌بندها (Rokach, 2006) موجب رشد روزافزون استفاده از این سیستم‌ها در حوزه‌های کاربردی بسیاری، از جمله پزشکی (Das and Das, 2010)، بیوانفورماتیک (Liu, et al., 2010)، سنجش (Sengur, 2010)، موضوعات مالی (Kim, 2010) (Hsieh and Hung, 2010)، امنیت (and Kang, 2010) و ... شده است. یک سیستم ترکیب طبقه‌بندها از دو قسمت اصلی طراحی طبقه‌بندهای پایه و به کارگیری قاعده ترکیب مناسب تشکیل شده است

<sup>1</sup> Classifier Ensemble

<sup>2</sup> Ensemble System

<sup>3</sup> Diversity

<sup>4</sup> Error Diversity





طبقه‌بندهای پایه به صورت مستقل روی مسئله آموزش می‌بینند و سپس خروجی طبقه‌بندهای لایه اول در قالب مجموعه‌ای دیگر جمع‌آوری می‌شود. درواقع به‌ازای هر نمونه ورودی اصلی، خروجی طبقه‌بندهای پایه به عنوان جایگزینی برای نمایش الگوی آن ورودی لحاظ شده و به طبقه‌بند دیگری در لایه دوم داده می‌شود. طبقه‌بند لایه دوم با گرفتن خروجی طبقه‌بندهای پایه لایه اول به عنوان ورودی و انجام چرخه یادگیری، تصمیم نهایی را اتخاذ می‌کند. جزیيات این دو روش در ادامه شرح داده خواهد شد.

مستقل از نوع روش ترکیب خروجی، یکی از پارامترهای مؤثر بر کارایی ترکیب طبقه‌بندها، گوناگونی طبقه‌بندهای پایه است. به‌طور شهودی و تجربی نشان داده شده است که گوناگونی مناسب کارایی ترکیب را تا حد زیادی افزایش می‌دهد (Brown, et al., 2005). به همین دلیل بسیاری از روش‌های ترکیب در مرحله طراحی پایه، به دنبال ایجاد گوناگونی در طبقه‌بندهای پایه هستند (Brown, et al., 2004).

راههای مختلفی برای ایجاد گوناگونی در خطاب پیشنهاد شده است که از آن جمله می‌توان به استفاده از روش‌های یادگیری متفاوت، گوناگونی در بازنمایی الگوی<sup>۱۱</sup> ورودی و گوناگونی در مجموعه یادگیری<sup>۱۲</sup> اشاره کرد (Kuncheva, 2004).

روش یادگیری مبتنی بر ایجاد همبستگی منفی یا به صورت خلاصه، یادگیری همبستگی منفی<sup>۱۳</sup> (Liu and Yao, 1999) از جمله روش‌هایی است که به‌طور ضمنی یادگیری طبقه‌بندهای پایه را متفاوت می‌کند و از این طریق طبقه‌بندهای گوناگون<sup>۱۴</sup> می‌سازد. در این روش از شبکه‌های عصبی به عنوان طبقه‌بندهای پایه استفاده می‌شود. این روش با اضافه کردن اصطلاح جریمه<sup>۱۵</sup> ای به تابع خطای ترکیب شبکه‌های عصبی، موجب می‌شود که طبقه‌بندهای عصبی در حین یادگیری برای کاهش خطای خود، خروجی‌های خود را تا حدی از هم متفاوت کنند. به این ترتیب روش یادگیری همبستگی منفی، به اعمال گوناگونی بین طبقه‌بندهای پایه می‌پردازد. در این مقاله تأثیر ایجاد گوناگونی ناشی از یادگیری همبستگی منفی بر کارایی ترکیب طبقه‌بندهای عصبی مورد بررسی قرار گرفته است.

<sup>11</sup> Different Representation

<sup>12</sup> Different Training Set

<sup>13</sup> Negative Correlation Learning

<sup>14</sup> Diverse Classifiers

<sup>15</sup> Penalty Term

شده است (Chen, 2008). از نقطه‌نظر وجود یا عدم وجود چرخه یادگیری<sup>۱</sup>، روش‌های ترکیب به دو گروه ۱- روش‌های ایستا<sup>۲</sup> و ۲- روش‌های مبتنی بر یادگیری<sup>۳</sup> تقسیم‌بندی می‌شوند (Kuncheva, 2004). در روش‌های ترکیب ایستا، بعد از این که هر یک از طبقه‌بندهای پایه، آموزش دیدند نیازی به انجام چرخه یادگیری برای ترکیب خروجی‌ها نیست. روش‌های میانگین گیری<sup>۴</sup>، رأی اکثربیت<sup>۵</sup> و Kuncheva, Kuncheva, et al., 1999)، کلیشهٔ تصمیم<sup>۶</sup> (2001)، از جمله روش‌های ترکیب ایستا محسوب می‌شوند. اما در گروه دیگر، برای تنظیم پارامترهای ترکیب طبقه‌بندهای پایه، چرخه‌ای مبتنی بر یادگیری لحاظ شده است.

روش‌های تعمیم انباره‌ای<sup>۷</sup> (Wolpert, 1992) و اختلال خبره‌ها<sup>۸</sup> (Jacobs, et al., 1991)، از جمله مهمترین روش‌های ترکیب مبتنی بر یادگیری به‌شمار می‌آیند. روش‌های کلیشهٔ تصمیم و تعمیم انباره‌ای به عنوان نماینده‌هایی از دو گروه اصلی روش‌های ترکیب در بررسی این مقاله مورد استفاده قرار گرفته است.

روش کلیشهٔ تصمیم از جمله روش‌های ایستا و بدون نیاز به یادگیری است (Kuncheva, 2004). این روش یکی از روش‌های ترکیب پایدار<sup>۹</sup> است که با ساختن ماتریس نمایهٔ تصمیم<sup>۱۰</sup> از خروجی همه طبقه‌بندهای پایه و مقایسه آن با ماتریس کلیشهٔ تصمیم هر طبقه عمل طبقه‌بندی را انجام می‌دهد. در ابتدا به‌ازای ورودی سیستم، ماتریس نمایه تصمیم، از کنار هم قرار گرفتن خروجی طبقه‌بندهای پایه شbahet آن با ماتریس کلیشهٔ تصمیم هر طبقه، که نماینده آن طبقه محسوب می‌شود، محاسبه می‌گردد. در نهایت داده ورودی به طبقه‌ای مناسب می‌شود که بیشترین میزان شباهت بین ماتریس نمایه تصمیم با ماتریس کلیشهٔ تصمیم آن طبقه برقرار باشد.

روش تعمیم انباره‌ای از جمله روش‌های ترکیب مبتنی بر یادگیری است (Wolpert, 1992). در این روش ابتدا

<sup>1</sup> Learning Process

<sup>2</sup> Static

<sup>3</sup> Learning-Based

<sup>4</sup> Averaging

<sup>5</sup> Majority Voting

<sup>6</sup> Decision Template

<sup>7</sup> Stacked Generalization

<sup>8</sup> Mixture of Experts

<sup>9</sup> Stable

<sup>10</sup> Decision Profile

(Kuncheva, 2001). نحوه کارکرد روش کلیشة تصمیم به این ترتیب است که بهازای ورودی سیستم  $w$  ماتریس نمایه تصمیم از روی بردارهای خروجی همه طبقه‌بندی‌های پایه ساخته می‌شود. ماتریس کلیشة تصمیم بهازای هر یک از طبقه‌های مسئله ساخته شده، به نحوی که کلیشة تصمیم هر طبقه بیان گر میانگین ماتریس‌های نمایه تصمیم ورودی‌های مربوط به آن طبقه است. برای طبقه‌بندی داده آزمون<sup>۳</sup>، پس از ساخت ماتریس نمایه تصمیم این ماتریس با ماتریس‌های کلیشة تصمیم همه طبقه‌ها مقایسه می‌شود. برای مقایسه با درنظر گرفتن معیار فاصله‌ای، شباهت نمایه تصمیم با کلیشه‌های تصمیم همه طبقه‌ها سنجیده می‌شود. این مقدار شباهت می‌تواند به عنوان تخمینی از احتمال تعلق داده ورودی به هر یک از کلاس‌های مسئله تعبیر شود. درنهایت داده ورودی به طبقه‌ای با بیشترین میزان شباهت نسبت داده می‌شود. در ادامه روش کلیشة تصمیم را به صورت دقیق و با فرمول‌بندی ریاضی شرح خواهیم داد.

فرض کنید  $L$  طبقه‌بند و  $C$  طبقه داشته باشیم و مجموعه  $W, D$  به ترتیب بیان گر مجموعه طبقه‌بندها و مجموعه طبقه‌ها باشد:

$$D = \{D_1, \dots, D_L\}, \quad W = \{w_1, \dots, w_C\}$$

هر طبقه‌بند  $D_i$  بهازای داده ورودی  $x$  یک بردار خروجی به صورت:

$$D_i(x) = \{d_{i,1}(x), \dots, d_{i,C}(x)\}$$

تولید می‌کند که در آن  $d_{i,j}(x)$  امتیاز تعلق الگوی  $x$  به طبقه  $w_j$  است.

ماتریس نمایه تصمیم از زیر هم قرار گرفتن تردارهای خروجی  $L$  طبقه‌بند پایه بهازای ورودی  $x$  ساخته می‌شود:

$$DP(x) = \begin{pmatrix} d_{1,1} & \dots & d_{1,C} \\ \vdots & d_{k,s} & \vdots \\ d_{L,1} & \dots & d_{L,C} \end{pmatrix} \quad (1)$$

که مشابه قبل، در ماتریس نمایه تصمیم  $(x)$  امتیاز تعلق الگوی  $x$  به کلاس  $w_s$  است که توسط طبقه‌بند تخمین زده شده است.

حال نحوه ساخت ماتریس‌های کلیشة تصمیم را ارائه می‌کنیم. ماتریس  $DT_i$  کلیشة تصمیم کلاس  $\Lambda^*$ ، با میانگین‌گیری از درایه‌های نظری به نظیر ماتریس‌های نمایه تصمیم داده‌های طبقه  $\Lambda^*$  ایجاد می‌شود. بیان ریاضی تشکیل ماتریس  $[DT_i(k,s)(x)] = [dt_i(k,s)(x)]$  به صورت رابطه زیر است:

<sup>3</sup> Test data

سال ۱۳۹۰ شماره ۲ پیاپی ۱۶

برای این تحقیق یک سیستم ترکیبی در نظر گرفته شده است که در بخش اول از یادگیری همبستگی منفی در طراحی و چرخه یادگیری طبقه‌بندی‌های پایه استفاده می‌کند. این وضعیت با حالتی که طبقه‌بندی به صورت مستقل<sup>۱</sup> (بدون استفاده از روش همبستگی منفی) آموزش می‌بینند مقایسه شده است. در بخش دوم سیستم ترکیبی از دو روش ترکیبی کلیشة تصمیم و تعمیم انبارهای به عنوان نماینده‌های دو گروه اصلی ترکیب استفاده شده و تأثیر استفاده از یادگیری همبستگی منفی بر کارایی این دو روش بررسی شده است.

ادامه مقاله به این ترتیب است که: در بخش دوم روش‌های ترکیبی مورد استفاده شرح داده شده است. در ابتدای بخش سوم، توضیحات روش یادگیری همبستگی منفی آورده شده و در ادامه ایده پیشنهادی این تحقیق ارائه شده است. نتایج آزمایش‌ها بر روی مجموعه داده‌های آزمون طبقه‌بندی در بخش چهارم آورده شده و در پایان، نتایج تحقیق در بخش پنجم مورد بحث و بررسی قرار گرفته است.

## ۲- روش‌های ترکیب طبقه‌بندی‌های عصبی

در این فصل نحوه عملکرد دو روش متداول ترکیب طبقه‌بندی‌های عصبی شامل کلیشة تصمیم و تعمیم انبارهای ارائه شده است. یکی از مزیت‌های عمدۀ این دو روش در مقایسه با روش‌های دیگر ترکیب از جمله روش‌های رأی اکثریت، بیشینه، کمینه و ... (Kittler, et al., 1998)، این است که دو روش مذکور از تمام خروجی شبکه‌های عصبی پایه در فرآیند ترکیب استفاده می‌کنند. از آن جا که خروجی شبکه عصبی به صورت تخمین احتمال پسین تعلق داده به طبقه متناظر قابل تعبیر است (Richard and Lippmann, 1991) این دو روش با بهره‌گیری از اطلاعات احتمالی تمام بردار خروجی شبکه‌های عصبی پایه، کارایی بهتری را از روش‌های ترکیب دیگر دارند.

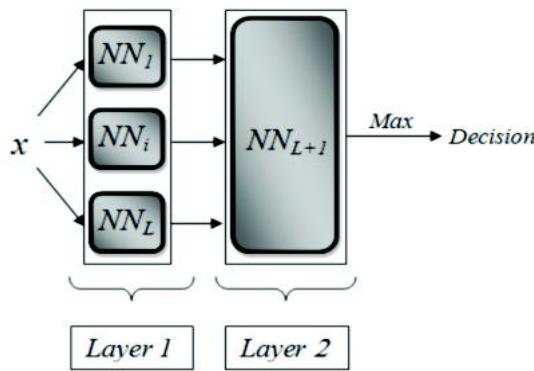
### ۲-۱- کلیشة تصمیم

در این روش ابتدا طبقه‌بندی‌های پایه به صورت مستقل از هم روی مجموعه یادگیری<sup>۲</sup> آموزش می‌بینند. روش کلیشة تصمیم بر پایه ساخت ماتریس‌های کلیشة و نمایه تصمیم و مقایسه آن‌ها کار می‌کند (Kuncheva, et al., 1999).

<sup>1</sup> Independent

<sup>2</sup> Training Set

وروودی لحاظ شده و درواقع طبقه بندهای لایه اول را می توان به عنوان تبدیلی غیرخطی<sup>۲</sup> برای تغییر فضای ورودی در نظر گرفت. خروجی طبقه بندهای لایه اول به شبکه عصبی دیگری در لایه دوم داده می شود. به این ترتیب، اگر مشابه قبل فرض کنیم  $L$  طبقه بند و  $C$  طبقه داشته باشیم، در این روش طبقه بند عصبی لایه دوم شبکه ای با  $L^*C$  ورودی و  $C$  خروجی خواهد بود. شبکه عصبی لایه دوم با گرفتن خروجی طبقه بندهای لایه اول به عنوان ورودی، مورد آموزش قرار می گیرد تا تصمیم نهایی را اتخاذ کند. شکل زیر به صورت نمادین ساختار روش تعیین انبارهای را نشان می دهد.



(شکل ۲): شمایی کلی عملکرد روش ترکیب تعیین انبارهای در طبقه‌بندی داده آزمون. در این شکل  $NN$  نمادی از طبقه‌بند عصبی  $\text{NaM}$  است.

## ۳- یادگیری مبتنی بر ایجاد همبستگی منفی

اکثر روش‌های ترکیب شبکه‌های عصبی، شبکه‌های پایه را به صورت توالی پی در پی<sup>۳</sup> و یا به صورت همزمان<sup>۴</sup> و مستقل از یکدیگر آموزش می‌دهند. یکی از اشکالات این روش‌ها، فقدان ارتباط و همکاری میان شبکه‌های پایه در فرآیند یادگیری و حل مسأله است. روش یادگیری مبتنی بر ایجاد همبستگی منفی یا به صورت خلاصه، یادگیری همبستگی منفی (Liu and Yao, 1999) روشی است که این اشکال روش‌های پیشین را برطرف کرده و آموزش شبکه‌های عصبی پایه را همراه با ارتباط چندسویه میان آنها و به صورت همزمان انجام می‌دهد.

این روش یک اصطلاح جریمه همبستگی<sup>۵</sup> به تابع خطای هر یک از شبکه‌های پایه اضافه می‌کند. در طول فرآیند یادگیری تمام طبقه‌بندهای پایه با این دوره جریمه تابع خطای با یکدیگر ارتباط خواهند داشت.

$$dt_i(k, s)(x) = \frac{\sum_{j=1}^N Ind(x_j, w_i) dp_{k,s}(x_j)}{\sum_{j=1}^N Ind(x_j, w_i)} \quad (\mathfrak{I})$$

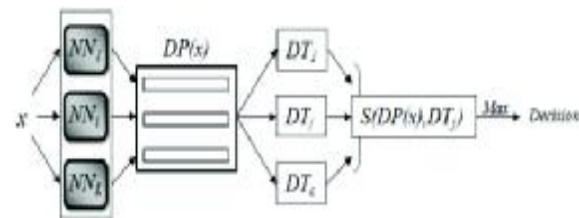
که در آن  $N$ , تعداد اعضای مجموعه  $\text{يادگيري}$  تابع  $(w_i, Ind(x_i))$  برای الگوی  $x_i$  متعلق به کلاس  $w_i$  یک و در غير اين صورت صفر است. پس از آنکه ماترييس کليشة تصميم ساخته شد، بهمنظور تعين عضويت داده آزمون، در ابتدا به توجه به خروجي طبقه بندها، ماترييس نمایه تصميم در مورد الگوی ورودی تشکيل شده و سپس بر مبناي شbahet ماترييس نمایه تصميم با ماترييس کليشة تصميم طبقه ها، الگوی مورد نظر طبقه بندی مى شود. بهمنظور تعين شbahet از معيارهای متفاوتی استفاده شده است. يکی از اين معيارهای اصله اقلیدسی طبق رابطه زير است:

$$S(DT_i, DP(x)) = 1 - \frac{1}{LC} \sum_{k=1}^L \sum_{s=1}^C \sqrt{\sum_{j=1}^n (dt_i(k,s)(x) - dP_{(k,s)}(x))^2} \quad (\dagger)$$

که تابع  $\mathcal{L}$  میزان شباهت ماتریس نمایه تصمیم ورودی  $DP(x)$  با کلیشة تصمیم طبقه  $i$ ,  $DT_i$ , را مشخص می‌کند. و درنهایت داده ورودی  $x$  به طبقه  $m$  با بیشترین میزان شباهت نسبت داده می‌شود:

$$m = \arg \max_i \left( S(DT_i, DP(x)) \right) \quad (\dagger)$$

(تصویر ۱) شمای کلی از فرآیند طبقه‌بندی داده آزمون را در سیستم ترکیبی کلیشة‌تضمیم را نشان می‌دهد:



(شکل ۱): شمای کلی عملکرد روش کلیشه تضمیم در طبقه‌بندی داده آزمون. در این شکل  $NN$ -نمادی از طبقه‌بند عصبی  $\text{GAM}$  است.

## ۲- روش تعمیم انبارهای

روش تعمیم انبارهای روشنی مبتنی بر یادگیری برای ترکیب طبقه‌بندهاست (Wolpert, 1992). ساختار روش تعمیم انبارهای از دو سطح تشکیل شده است. در سطح اول، طبقه‌بندهایی قرار دارند که روی داده‌های مجموعه یادگیری به صورت مستقل آموزش می‌بینند. پس از اتمام آموزش، خروجی طبقه‌بندهای لایه اول به‌ازای تمام داده‌های مجموعه یادگیری، جمع‌آوری شده و در مجموعه‌ای جدید قرار می‌گیرد. درواقع به‌ازای هر نمونه ورودی اصلی، خروجی طبقه‌بندهای پایه به عنوان جایگزینی برای نمایش الگوی آن

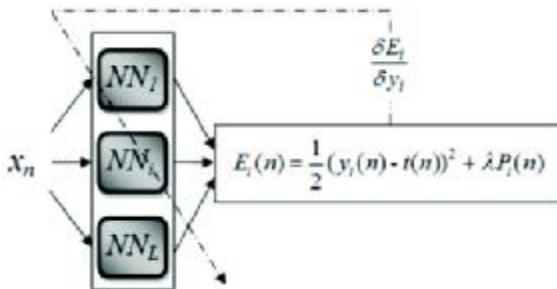
## <sup>2</sup> Nonlinear Transformation

### <sup>3</sup> Nonlocal Sequential

## <sup>4</sup> Synchronize

## <sup>5</sup> Correlation Penalty

### <sup>1</sup> Similarity



(شکل ۳): شماتی فرآیند یادگیری طبقه‌بندی‌های عصبی پایه در یادگیری همبستگی منفی. در این شکل  $NN_i$  نمادی از طبقه‌بند عصبی نام است

اصطلاح جریمه همبستگی با کاهش میزان همبستگی، موجب ایجاد گوناگونی مطلوبی بین طبقه‌بندی‌های پایه می‌شود که کارایی سیستم ترکیبی را افزایش خواهد داد. از آن جایی که روش یادگیری همبستگی منفی دوره گوناگونی را به صورت مستقیم در تابع خطای شبکه عصبی وارد می‌کند، جزء روش‌های صریح ایجاد گوناگونی محسوب می‌شود (Nabavi, 2004).

### ۱-۳- روش یادگیری همبستگی منفی برای ایجاد گوناگونی در ترکیب شبکه‌های عصبی

استفاده از طبقه‌بندی‌های عصبی گوناگون<sup>۲</sup> می‌تواند کارایی سیستم ترکیب طبقه‌بندی‌ها را افزایش دهد. در صورتی ایجاد گوناگونی بین طبقه‌بندی‌های پایه موجب بیشترین تأثیر بر کارایی ترکیب خواهد شد که میزان گوناگونی اعمال شده با توجه به مسئله مورد نظر قابل کنترل باشد (Nabavi, 2004; Kittler and Roli, 2000; Ghaderi, 2000).

روش یادگیری همبستگی منفی با لحاظ کردن پارامتر تنظیم توان تابع جریمه،  $\lambda$ ، این قابلیت را دارد. به همین دلیل روش ارائه شده در این مقاله، در مرحله اول سیستم ترکیبی از این روش برای آموزش و گوناگون کردن شبکه‌های عصبی پایه استفاده می‌کند. در مرحله بعدی دو روش کلیشه تضمیم و تعمیم انبارهای به عنوان نماینده‌هایی از دو گروه اصلی روش‌های ترکیب، مورد استفاده قرار گرفته و تأثیر استفاده از یادگیری همبستگی منفی بر کارایی آنها بررسی شده است.

روش ارائه شده در این مقاله از نقطه نظر دیگری هم قابل بررسی است. تاکنون برای ترکیب طبقه‌بندی‌های عصبی حاصل از یادگیری همبستگی منفی از روش‌های

تابع خطای شبکه نام،  $E_i$ ، به‌ازای ورودی  $n$  در روش یادگیری همبستگی منفی به این شکل تعریف می‌شود:

$$E_i(n) = \frac{1}{2} (y_i(n) - t(n))^2 + \lambda P_i(n) \quad (5)$$

که  $y_i(n)$  و  $t(n)$  به ترتیب خروجی شبکه عصبی نام و خروجی مطلوب و  $P_i(n)$  تابع جریمه همبستگی به‌ازای ورودی  $n$  است.

تابع همبستگی  $P_i$  به شکل زیر تعریف می‌شود:

$$P_i(n) = \frac{1}{2} (y_i(n) - \bar{y}(n))^2 \quad (6)$$

که  $\bar{y}(n)$  میانگین خروجی‌های شبکه‌های عصبی به‌ازای ورودی  $n$  است.

با لحاظ کردن این تابع خطای، هر شبکه عصبی در ضمن کاهش خطای خود، سعی می‌کند که پارامتر  $P_i$  را نیز کمینه نماید. پارامتر  $0 \leq \lambda \leq 1$  برای تنظیم توان<sup>۱</sup> تابع جریمه استفاده شده است. کمینه کردن اصطلاح ۵ مستلزم آن است که هر شبکه علاوه بر کاهش خطای خود، همبستگی‌اش با سایر شبکه‌های عصبی را نیز کاهش دهد. با تنظیم پارامتر توان تابع جریمه می‌توان مقدار این کاهش را تا حدی تنظیم کرد که همبستگی بین شبکه‌های عصبی پایه منفی شود که این امر خطای طبقه‌بندی سیستم ترکیبی را بیش از پیش کاهش خواهد داد. دلیل نام‌گذاری این روش نیز همین مکانیزم ایجاد همبستگی منفی بین شبکه‌های پایه است. از نقطه نظر دیگر، وجود این اصطلاح جریمه همبستگی باعث می‌شود که شبکه‌های پایه در حل مسئله با یکدیگر همکاری کرده و هر کدام جنبه‌ها یا قسمت‌های مختلفی از مسئله را مورد بررسی قرار دهند (Liu and Yao, 1999).

در روش یادگیری همبستگی منفی از روش پس‌انتشار خطای در حالت الگویه‌الگو برای اصلاح و هم‌گرایی مقادیر وزن‌های شبکه‌های عصبی استفاده می‌شود. بدین منظور مشتق جزیی تابع خطای  $E_i$  نسبت به خروجی  $y_i$  به‌ازای ورودی  $n$  به این شکل محاسبه می‌شود:

$$\frac{\delta E_i(n)}{\delta y_i(n)} = y_i(n) - t(n) + \lambda(y_i(n) - \bar{y}(n)) \quad (7)$$

و اصلاح وزن‌های شبکه‌های پایه سیستم ترکیبی بر اساس این فرمول به صورت همزمان انجام می‌شود. نحوه عملکرد روش یادگیری همبستگی منفی در شکل زیر به صورت نمادین نمایش داده شده است.

<sup>1</sup> Strength

<sup>2</sup> Diverse Neural Classifiers

سال ۱۳۹۰ شماره ۲ پیاپی ۱۶

### ۳. دیابت<sup>۴</sup>

یک مجموعه‌داده دو طبقه است که شامل ۷۶۸ نمونه است که ۵۰۰ نمونه آن مربوط به کلاس اول با برچسب مثبت بودن آزمایش دیابت و ۲۶۸ نمونه آن مربوط به طبقه دوم با برچسب منفی بودن آزمایش دیابت است. بُردار ویژگی نمونه‌ها یک بُردار<sup>۸</sup> بعدی از مشخصات هر فرد است.

### ۴. سرطان پستان<sup>۵</sup>

سرطان پستان یک مجموعه‌داده دو طبقه، شامل ۶۸۳ نمونه است. ۴۴۴ نمونه آن مربوط به طبقه سرطان بدخیم و ۲۳۹ نمونه آن مربوط به طبقه سرطان خوشخیم است. بُردار ویژگی نمونه‌ها یک بُردار ۱۰ بعدی است.

### ۵. امواج خورشیدی<sup>۶</sup>

این مجموعه‌داده طبقه‌بندی بر اساس تمایز نحوه انعکاس مواد مختلف در شرایط متفاوت تهیه شده است و می‌تواند آزمونی برای سیستم‌های طبقه‌بندی باشد تا از روی فرکانس انعکاس تشعشعات خورشیدی بتوانند نوع ماده را تشخیص دهند. این مجموعه داده دو طبقه از ثبت نحوه انعکاس دو ماده استوانه‌ای فلزی و استوانه‌ای سنگی که تحت تابش در شرایط و زوایای مختلفی قرار گرفته‌اند تهیه شده است. این داده شامل ۲۰۸ نمونه (۱۱۱ نمونه از کلاس اول و ۹۷ نمونه از کلاس دوم) که بُردار اطلاعات هر نمونه شامل ۶۰ ویژگی کمی است.

اطلاعات کمی این پنج مجموعه‌داده آزمون طبقه‌بندی به صورت خلاصه در (جدول ۱) آورده شده است.

(جدول ۱): اطلاعات مربوط به مجموعه‌داده‌های آزمون طبقه‌بندی

سایز مجموعه یادگیری	سایز مجموعه داده	ابعاد بردار ویژگی	تعداد کلاس	مجموعه داده
۴۵۰	۱۵۰۰	۴	۶	تصاویر ماهواره‌ای
۲۵۰	۸۴۶	۱۸	۴	وسایل نقلیه
۲۳۰	۷۶۸	۸	۲	دیابت
۱۷۰	۵۷۶	۳۰	۲	سرطان پستان
۶۰	۲۰۸	۶۰	۲	امواج خورشیدی

در آزمایش‌های این مقاله از پنج شبکه عصبی پرسپترون چندلایه<sup>۷</sup> با یک لایه مخفی<sup>۸</sup> به عنوان

<sup>4</sup> Pima Indian Diabetes

<sup>5</sup> Breast Cancer

<sup>6</sup> Sonar

<sup>7</sup> Multi-Layer Perceptrons

<sup>8</sup> Hidden Layer

میانگین‌گیری و رأی اکثریت استفاده می‌شد که در این تحقیق استفاده از روش‌های کاراتر کلیشه تصمیم و تعمیم انباره‌ای پیشنهاد شده است.

برای لحاظ‌کردن هر دو دیدگاه از روش پیشنهادی ما در طراحی آزمایش‌ها، دو مجموعه آزمایش انجام و نتایج آنها مورد مقایسه قرار گرفته است. بر طبق دیدگاه اول یعنی بررسی تأثیر یادگیری همبستگی منفی بر کارایی سیستم ترکیبی، کارایی سیستم ترکیب طبقه‌بندها در حالت استفاده از این روش با حالت عدم استفاده و یادگیری مستقل مقایسه می‌شود. بر طبق دیدگاه دوم که ادعا دارد روش‌های کلیشه تصمیم و تعمیم انباره‌ای روش‌های بهتری برای ترکیب طبقه‌بندهایی با همبستگی منفی هستند، مقایسه دیگری انجام شده است. در این حالت کارایی دو روش ترکیب پیشنهادی با روش‌های مورد استفاده پیشین شامل میانگین‌گیری و رأی اکثریت مقایسه می‌شود.

## ۴- نتایج آزمایش‌ها

پنج مجموعه‌داده آزمون طبقه‌بندی<sup>۱</sup> از بانک داده UCI (Frank and Asuncion, 2010) و ELENA آزمایش استفاده شده که توضیحات مختصری از اطلاعات آنها در ذیل آورده می‌شود:

### ۱. تصاویر ماهواره‌ای<sup>۲</sup>

این مجموعه‌داده مربوط به تصاویر ماهواره‌ای چندطیفی است. این داده‌ها شامل ۶۴۳۵ پیکسل با ۳۶ ویژگی است. پیکسل‌های تصویر مربوط به پوشش‌های مختلف گیاهی سطح زمین است که در ۶ طبقه دسته‌بندی می‌شوند. زیاد بودن تعداد نمونه‌ها، مقداری بودن ویژگی‌ها، یکسان بودن محدوده مقداری ویژگی‌ها و معلوم بودن همه مقداری از ویژگی‌های جالب این مجموعه‌داده است.

### ۲. وسایل نقلیه<sup>۳</sup>

این مجموعه‌داده از تصاویر دو بعدی انواع مختلفی از وسایل نقلیه با استخراج ویژگی هندسی از تصویر آنها ساخته شده و شامل ۹۴۶ نمونه از چهار وسیله نقلیه مختلف از جمله اپل، ساب، اتوبوس و ون است. از هر تصویر بُردار ویژگی هندسی با ۱۸ ویژگی استخراج شده و تعداد اعضای چهار طبقه این مسئله بهطور تقریبی با هم برابر است.

<sup>1</sup> Classification Benchmark

<sup>2</sup> Satellite Image

<sup>3</sup> Vehicle



کوچک بودن حجم مجموعه یادگیری، ساختار شبکه‌های عصبی پایه نیز باید متناسب با آن انتخاب شود. از این‌رو شبکه‌های پایه از نوع طبقه‌بندهایی ساده با پیچیدگی ساختاری کم انتخاب شده‌اند (Ghaderi, 2000). نحوه تعیین ساختار شبکه‌های پایه به این ترتیب بوده است که در ابتدا تعداد بهینه نمونه‌های لایه میانی یک شبکه عصبی منفرد در یک فرآیند آزمون و خطا تعیین شده و سپس این تعداد به نسبت تاحدودی مساوی میان شبکه‌های پایه تقسیم شده است. ساختار بهینه شبکه عصبی ترکیب‌کننده در روش تعیین انباره‌ای نیز بر اساس آزمودن تعداد مختلف نمونه‌های لایه میانی و انتخاب وضعیت برتر بر اساس کارایی بیشینه، روی مجموعه اعتبارسنجی انجام شده است.

شبکه‌های عصبی ساختار ترکیب با نرخ یادگیری<sup>۱</sup> روی مجموعه یادگیری آموزش دیده‌اند. در این تحقیق پارامتر توان جرمیه همبستگی بهازی مقادیر مختلف در بازه [۰:۰:۱] آزموده شده و بهازی هر مسأله بیشترین کارایی طبقه‌بندی حاصل از مقدار بهینه آن در مجموعه اعتبارسنجی، در جداول گزارش شده است.

برای بررسی تأثیر ایجاد گوناگونی ناشی از یادگیری همبستگی منفی بر کارایی روش‌های ترکیب کلیشه تصمیم و تعیین انباره‌ای آزمایش‌هایی انجام شده است که در حالت اول شبکه‌های پایه بهصورت مستقل از هم و در حالت دوم با استفاده از یادگیری همبستگی منفی آموزش دیده‌اند. خروجی شبکه‌های پایه در این دو حالت با استفاده از روش کلیشه تصمیم و تعیین انباره‌ای ترکیب شده‌اند که نتایج بهتری در جداول ۳ و ۴ آورده شده است.

(جدول ۳): نتایج مربوط به کارایی روش ترکیبی کلیشه تصمیم، در حالت یادگیری همبستگی منفی در مقایسه با یادگیری مستقل طبقه‌بندهای پایه.

یادگیری همبستگی منفی + کلیشه تصمیم	یادگیری مستقل + کلیشه تصمیم	میانگین کارایی مجزای طبقه‌بند پایه	مجموعه داده
۶۷/۶	۶۶	۶۰/۳	تصاویر ماهواره‌ای
۷۱/۵	۶۸/۲۳	۶۵/۷	وسایل نقلیه
۷۳/۲۹	۷۱/۴	۶۶/۹	دیابت
۹۲/۰۷	۸۸/۰۴	۷۹/۵	سرطان پستان
۶۶/۱	۶۴/۲۷	۶۰/۰۸	امواج خورشیدی

<sup>۶</sup> Learning Rate

سال ۱۳۹۰ شماره ۲ پیاپی ۱۶

طبقه‌بندهای پایه استفاده شده است. اطلاعات ساختار سیستم‌های ترکیبی مورد استفاده برای طبقه‌بندی هر مجموعه‌داده در (جدول ۲) آورده شده است. این اطلاعات شامل تعداد و ساختار هر شبکه عصبی پایه و نیز ساختار شبکه عصبی ترکیب‌کننده مورد استفاده در روش تعیین انباره‌ای است. برای محاسبه کارایی روش‌های مورد بررسی از ایده اعتبارسنجی تکراری با زیرمجموعه‌های تصادفی<sup>۱</sup> استفاده شده است، به این نحو که مجموعه‌داده در هر بار تکرار آزمون، به سه زیرمجموعه شامل مجموعه یادگیری، مجموعه اعتبارسنجی<sup>۲</sup> و مجموعه آزمون به نسبت تقریبی به ترتیب ۳۰، ۳۰ و ۴۰٪ بهصورت تصادفی تقسیم می‌شود.

(جدول ۲): ساختار سیستم ترکیبی مورد استفاده در هر یک از

مسائل آزمون طبقه‌بندی. اطلاعات ساختاری به صورت (n) [x:y:z] ارائه شده که n نشان‌گر تعداد شبکه پایه و z,y,x به ترتیب بیان گر تعداد نمون در لایه ورودی، میانی و خروجی شبکه‌های عصبی است.

مجموعه داده	ساختار شبکه عصبی ترکیب	سیستم ترکیبی	کننده در روش تعیین انباره‌ای
تصاویر ماهواره‌ای	[۵*۶:۱۲:۶]	(۵)[۴:۸:۶]	
وسایل نقلیه	[۵*۴:۷:۴]	(۵)[۱۸:۴:۶]	
دیابت	[۵*۲:۸:۲]	(۵)[۸:۵:۲]	
سرطان پستان	[۵*۲:۱۴:۲]	(۵)[۳۰:۳:۲]	
امواج خورشیدی	[۵*۲:۱۵:۲]	(۵)[۶۰:۵:۲]	

مجموعه یادگیری برای هم‌گرایی پارامترهای ساختار شبکه عصبی استفاده و با بهره‌گیری از مجموعه اعتبارسنجی و ایده نقطه توقف زودهنگام<sup>۳</sup> از مشکل انطباق مفرط<sup>۴</sup> جلوگیری می‌شود. لازم به ذکر است که بهدلیل لحاظ کردن زیرمجموعه تاحدودی اندک از مجموعه داده، به عنوان مجموعه یادگیری، در حدود ۳۰٪ مشابه شرایط (Kuncheva, et al., 1999) استفاده از مجموعه اعتبارسنجی برای جلوگیری از مشکل مذکور ضروری است. در پایان فرآیند یادگیری، سیستم ترکیب شبکه‌های عصبی به دست آمده روی مجموعه آزمون اعمال شده و نرخ کارایی محاسبه می‌شود. نتایج گزارش شده، حاصل میانگین ده بار اجرای هر یک از روش‌های مورد بررسی با استفاده از فرآیند اعتبارسنجی یاد شده است. شایان توجه است که شرایط مجموعه یادگیری اندک<sup>۵</sup> برای نشان‌گذاری نتایج تعیین ساختار ترکیب شبکه‌های عصبی اتخاذ شده است. بهدلیل

<sup>۱</sup> Repeated Random Sub-Sampling Validation

<sup>۲</sup> Validation Set

<sup>۳</sup> Early Stopping point

<sup>۴</sup> Over-Fitting

<sup>۵</sup> Small Sample Size

همان طور که نتایج (جدول ۵) نشان می‌دهد، روش کلیشهٔ تصمیم و تعمیم انبارهای در ترکیب شبکه‌های پایه حاصل از یادگیری همبستگی منفی به‌طور قابل ملاحظه‌ای کارایی بالاتری از روش‌های پیشین شامل میانگین‌گیری و رأی اکثریت دارد.

برای مقایسهٔ دو روش کلیشهٔ تصمیم و تعمیم انبارهای، در دو وضعیت مختلف ترکیب شبکه‌های مستقل و نیز ترکیب شبکه‌های با همبستگی منفی، نتایج حاصل از (جدوال ۳ و ۵) مورد مقایسه قرار گرفت. نتایج مقایسه نشان می‌دهد که در وضعیت ترکیب شبکه‌های مستقل، کلیشهٔ تصمیم در ۸۰٪ موارد عملکرد بهتری داشته است. اما در وضعیت ترکیب شبکه‌هایی با همبستگی منفی، کلیشهٔ تصمیم برتری قابل توجهی نداشته و تنها در ۶۰٪ موارد از کارایی بالاتری برخوردار بوده است.

## ۵- جمع‌بندی و نتیجه‌گیری

در این مقاله تأثیر استفاده از شبکه‌های عصبی گوناگون حاصل از یادگیری همبستگی منفی بر کارایی ترکیب شبکه‌های عصبی بررسی شده است. در این روش شبکه‌های پایه بر مبنای یادگیری همبستگی منفی آموزش دیده و سپس این امکان وجود دارد که خروجی این شبکه‌ها توسط روش‌های مختلف ترکیب شوند. در این تحقیق دو روش کلیشهٔ تصمیم و تعمیم انبارهای به‌عنوان نماینده‌هایی از دو گروه اصلی روش‌های ترکیب (روش‌های ایستاد مقابله روش‌های مبتنی بر یادگیری) استفاده شده‌اند. بهره‌گیری از یادگیری همبستگی منفی توانسته به‌طور قابل ملاحظه‌ای کارایی هر دو روش ترکیب را افزایش دهد. این بهبود بدین شکل قابل توجیه است که چون در یادگیری همبستگی منفی شبکه‌های پایه در حل مسئله با یکدیگر همکاری کرده و هر کدام جنبه‌ها یا قسمت‌های مختلفی از مسئله را مورد بررسی قرار می‌دهند، درنتیجه ترکیب شبکه‌های پایه مکمل و گوناگون توانسته کارایی ترکیب را در مقایسه با شبکه‌های مستقل افزایش دهد.

این تحقیق از نقطه‌نظر دیگری نیز قابل بحث است. به این ترتیب که روش‌های پیشنهادی شامل کلیشهٔ تصمیم و تعمیم انبارهای، روش‌های کاراتری برای ترکیب شبکه‌هایی با همبستگی منفی هستند. این بررسی در مقایسه با روش‌های پیشین ترکیب شبکه‌هایی با همبستگی منفی شامل میانگین‌گیری و رأی اکثریت انجام شده است. نتایج آزمایش‌ها نشان داد که روش‌های پیشنهادی صحت طبقه‌بندی به مراتب بالاتری نسبت به روش‌های پیشین بوده‌اند.

همان طور که در نتایج (جدول ۳) مشخص است، با استفاده از یادگیری همبستگی منفی توانسته است در مقایسه با حالت یادگیری مستقل طبقه‌بندی‌های پایه، به‌طور قابل ملاحظه‌ای کارایی روش کلیشهٔ تصمیم را افزایش دهد.

(جدول ۴): نتایج مربوط به کارایی روش ترکیبی تعمیم انبارهای، در حالت یادگیری همبستگی منفی در مقایسه با یادگیری مستقل طبقه‌بندی‌های پایه.

مجموعه داده	میانگین کارایی $\frac{5}{5}$ طبقه بند پایه	یادگیری + تعمیم انبارهای	یادگیری همبستگی منفی + تعمیم انبارهای
تصاویر ماهواره‌ای	۶۰/۳	۶۴/۸	۶۶/۳
وسایل نقلیه	۶۵/۷	۷۰/۹۵	۷۳/۲
دیابت	۶۶/۹	۷۰/۱۶	۷۲/۸۲
سلطان پستان	۷۹/۲	۸۷/۶	۹۲/۸۴
امواج خورشیدی	۶۰/۰۸	۶۳/۲۹	۶۵

به‌طور مشابه، نتایج (جدول ۴) نشان می‌دهد که استفاده از یادگیری همبستگی منفی صحت طبقه‌بندی روش ترکیب تعمیم انبارهای را نیز به‌طور قابل ملاحظه‌ای نسبت به یادگیری مستقل طبقه‌بندی‌های پایه افزایش داده است.

همان طور که در قبل ذکر شد، بررسی انجام شده در این تحقیق از نقطه‌نظر دیگری هم قابل ارائه است. تاکنون روش‌های میانگین‌گیری و رأی اکثریت برای ترکیب شبکه‌های پایه با همبستگی منفی مورد استفاده بوده است. در این تحقیق ما دو روش دیگر شامل کلیشهٔ تصمیم و تعمیم انبارهای را برای ترکیب شبکه‌هایی با همبستگی منفی پیشنهاد داده‌ایم. نتایج مقایسه کارایی روش‌های پیشنهادی با روش‌های مورد استفاده پیشین در (جدول ۵) آورده شده است.

(جدول ۵): نتایج مربوط به مقایسه روش‌های ترکیب پیشین شبکه‌هایی با همبستگی منفی، شامل: میانگین‌گیری و رأی اکثریت در مقایسه با روش‌های پیشنهادی از جمله: کلیشهٔ تصمیم و تعمیم انبارهای.

مجموعه داده	یادگیری همبستگی منفی + میانگین گیری	یادگیری همبستگی منفی + رأی اکثریت	یادگیری همبستگی منفی + میانگین گیری	یادگیری همبستگی منفی + میانگین گیری	یادگیری همبستگی منفی + میانگین گیری	تصاویر ماهواره‌ای
تصاویر ماهواره‌ای	۶۳/۱	۶۴/۸	۶۷/۶	۶۵	۶۷/۶	۶۶/۳
وسایل نقلیه	۶۷/۹	۶۸/۷	۷۱/۵	۶۹/۴۸	۷۱/۵	۷۳/۲
دیابت	۶۸/۳	۷۰/۶۵	۷۳/۲۹	۶۹/۴	۷۳/۲۹	۷۲/۸۲
سلطان پستان	۸۸/۰۴	۸۹/۱۱	۸۹/۰۷	۸۹/۴	۹۲/۰۷	۹۲/۸۴
امواج خورشیدی	۵۹/۳۷	۶۲/۷	۶۲/۳۱	۶۲/۳۱	۶۶/۱	۶۵



ctionist+Bench+%28Sonar,+Mines+vs.+Rocks%29

<http://archive.ics.uci.edu/ml/datasets/Pima%20Indians%20Diabetes>

<http://archive.ics.uci.edu/ml/datasets/Statlog+Vehicle+Silhouettes%29>

<http://archive.ics.uci.edu/ml/support/Breast+Cancer+Wisconsin%28Original%29>

<http://www.dice.ucl.ac.be/neural-nets/research/projects/ELENA/database/REAL/Satimage>

[http://www.dice.ucl.ac.be/neural-nets/Research/Projects/ELENA/elena.htm.](http://www.dice.ucl.ac.be/neural-nets/Research/Projects/ELENA/elena.htm)

Hung M., Hu M., Shanker M., Patuwo B., 1996. Estimating posterior probabilities in classification problems with neural networks, Int. Journal of Computational Intelligence and Organizations, vol. 1, no. 1, pp.49-60.

Jacobs R.A., Jordan M.I., S.J. Nowlan, Hinton G.E., 1991. Adaptive mixtures of local experts, Neural Computation 3-79-87.

Kim M. J. and Kang D. K., 2010. "Ensemble with neural networks for bankruptcy prediction," Expert Systems with Applications, vol. 37, pp. 3373-3379.

Kittler J. and Roli F., "Multiple Classifier Systems", in Proc Int Work-shop on Multiple Classifieer Systems, 2000, Springer.

Kittler J., Hatef M., PRW. Duin, Matas J., 1998. On combining classifiers. IEEE Trans. Pattern Anal., vol. 20, no. 3, pp. 226-239.

Kuncheva L. I., 2004. Combining Pattern Classifiers: Methods and Algorithms. New York, NY: Wiley.

Kuncheva L. I., Bezdek J. C., and Duin R. P. W., 1999. "Decision templates for multiple classifier fusion: An experimental comparison", Pattern Recognition.

Kuncheva L.I., 2001. "Using measures of similarity and inclusion for multiple classifier fusion by decision templates", Fuzzy Sests Syst. Vol. 122, No.3, pp.401-407.

Liu H., Liu L., and Zhang H., 2010. "Ensemble gene selection by grouping for microarray data classification," Journal of Biomedical Informatics, vol. 43, pp. 81-87.

Liu Y. and Yao X., 1999. "Ensemble learning via negative correlation", Neural Networks Vol. 12, No. 10, pp. 1399-1404.

Liu Y. and Yao X., 1999. "Simultaneous training of

سال ۱۳۹۰ شماره ۲ پیاپی ۱۶

## سپاس‌گزاری

این تحقیق در قالب طرح پژوهشی "بهبود کارایی ترکیب شبکه‌های عصبی با استفاده از الگوریتم همگرایی منفی" با حمایت دانشگاه آزاد اسلامی واحد تهران جنوب انجام پذیرفته شده است.

## ۶- منابع

Brown G., 2004. Diversity in neural network ensembles, Ph.D. thesis, School of Computer Science, University of Birmingham.

Brown G., Wyatt J. L., Harris R., Yao X., 2005. Diversity creation methods: A survey and categorisation, Journal of Information Fusion, 6 pp. 5–20.

Chandra A., Yao X., 2004. "DIVACE: Diverse and accurate ensemble learning algorithm", in Proceedings of the fifth international conference on intelligent data engineering and automated learning (IDEAL 200), lecture notes in computer science, Vol. 3177. Berlin: Springer; pp. 619–25.

Chen H., 2008 Diversity and Regularization in Neural Network Ensembles, PhD Thesis, School of Computer Science University of Birmingham.

Cunningham P. and Carney J., 2000. "Diversity versus quality in classification ensembles based on feature selectio," in R.L. de Mántaras, E. Plaza (Eds.), Proceedings of the ECML2000. vol. 1810, ed Barcelona, Spain: Springer, Berlin, pp. 109-116.

Das R. and Sengur A., 2010. "Evaluation of ensemble methods for diagnosing of valvular heart disease," Expert Systems with Applications, vol. 37, pp. 5110-5115, 2010.

Dietterich T. G., 1997. "Machine learning research: Four current directions," Artificial Intell. Mag., vol. 18, pp. 97-136.

Frank A., and Asuncion A., 2010. UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>].Irvine, CA: University of California, School of Information and Computer Science.

Ghaderi R., 2000. "Arranging simple neural networks to solve complex classification problems," Ph.D. Thesis, Surrey University.

Hsieh N. C. and Hung L. P., 2010. "A data driven ensemble classifier for credit scoring analysis," Expert Systems with Applications, vol. 37, pp. 534-545.

<http://archive.ics.uci.edu/ml/datasets/Conne>





امیرحسین کاشفی در سال ۱۳۸۶ مدرک کارشناسی خود را در رشته مهندسی کامپیوتر از دانشگاه آزاد اسلامی واحد تهران جنوب دریافت کرد و مدرک کارشناسی ارشد خود را در

رشته علوم کامپیوتر در دانشگاه تهران در سال ۱۳۸۹ دریافت نمود. زمینه‌های مورد علاقه‌وى، یادگیری ماشین و تشخیص الگو، داده‌کاوی، ترکیب طبقه‌بندها و اصول ترکیبیات می‌باشد.

نشانی رایانمک ایشان عبارتست از:

[amirhosein.kashefi@gmail.com](mailto:amirhosein.kashefi@gmail.com)  
[a.kashefi@alumni.ut.ac.ir](mailto:a.kashefi@alumni.ut.ac.ir)

negatively correlated neural networks in an ensemble," IEEE Trans. Syst. Man Cybern. B, Cybern., vol. 29, no. 6, pp. 716–725.

Nabavi M., 2004. "Classifiers Combination with Emphasis on their Diversities", PhD Thesis, Tarbiat Modares University.

Polikar R., 2006. "Ensemble Based Systems in Decision Making", IEEE Circuits and Systems Magazine, Vol.6, No. 3, pp. 21-45.

Richard MD., Lippmann RP., 1991. Neural network classifiers estimate Bayesian a posteriori probabilities. Neural Comput., vol. 3, no. 4, pp. 461-483.

Rokach L., 2010. Ensemble-based classifiers, Artif Intell Rev, 33 pp. 1-39.

Tsymbal A., Pechenizkiy M., and Cunningham P., 2005, "Diversity in search strategies for ensemble feature selection," Information Fusion, vol. 6, pp. 83-98.

Wolpert D. H., 1992. "Stacked generalization", Neural Networks 5, 241- 259.

### علی کارگرنژاد در سال ۱۳۷۸ مدرک



کارشناسی خود را در رشته مهندسی کامپیوتر از دانشگاه آزاد اسلامی واحد تهران جنوب دریافت کرد و مدرک کارشناسی ارشد خود را در رشته هوش مصنوعی در دانشگاه آزاد واحد علوم تحقیقات در سال ۱۳۸۱ دریافت نمود. زمینه‌های مورد علاقه‌وى، هوش مصنوعی، سیستم‌های بیومتریک و سختافزار کامپیوتر می‌باشد.

نشانی رایانمک ایشان عبارتست از:

[kargarnejad@azad.ac.ir](mailto:kargarnejad@azad.ac.ir)  
[az\\_micro@yahoo.com](mailto:az_micro@yahoo.com)

### سعید مسعودنیا مدرک کارشناسی خود



را در سال ۱۳۸۷ در رشته علوم کامپیوتر از دانشگاه تهران جنوب دریافت کرد و مدرک کارشناسی ارشد خود را در رشته علوم کامپیوتر در همان دانشگاه در سال ۱۳۹۰ دریافت نمود. زمینه‌های مورد علاقه‌وى هوش مصنوعی و یادگیری ماشین، بینایی ماشین، پردازش الگو و ترکیب طبقه‌بندها می‌باشد.

نشانی رایانمک ایشان عبارتست از:

[s.masoudnia@gmail.com](mailto:s.masoudnia@gmail.com)  
[masoudnia@alumni.ut.ac.ir](mailto:masoudnia@alumni.ut.ac.ir)

فصل نهم  
کلیک

