استفاده از یادگیری همبستگی منفی در بهبود کارایی ترکیب شبکه‌های عصبی

علی کارگرنژاد [۱]، سعید مسعودنیا [۲] و امیرحسین کاشفی [۳]
[۱] دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران.
[۲] دانشگاه آزاد اسلامی، واحد تهران مرکز و باشگاه پژوهشگران جوان، تهران، ایران.
[۳] دانشگاه آزاد اسلامی، واحد تهران جنوب، باشگاه پژوهشگران جوان، تهران، ایران.

چکیده

یکی از روش‌های بهبود صحّت 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 پایهٔ سیستم اشاره کرد. در این مقاله تأثیر ایجاد گوناگونی حاصل از یادگیری همبستگی منفی را در دو روش ترکیبی کلیشهٔ تصمیم و تعمیم انباره‌ای مورد بررسی قرار داده‌ایم. استفاده از یادگیری همبستگی منفی برای ایجاد گوناگونی در طبقه‌بندهای پایهٔ سیستم ترکیبی، صحّت طبقه‌بندی را در هر دو روش مورد آزمون بهبود داده است. ایدهٔ پیشنهادی مقاله از نقطه‌نظر دیگری هم قابل ارائه است؛ نتایج این تحقیق نشان داد که کلیشهٔ تصمیم و تعمیم انباره‌ای نسبت به روش های دیگر، روش‌های کاراتری برای ترکیب شبکه‌های حاصل از یادگیری همبستگی منفی هستند.

واژگان کلیدی: ترکیب طبقه‌بندهای عصبی، یادگیری همبستگی منفی ، گوناگونی، کلیشهٔ تصمیم و تعمیم انباره‌ای.

۱- مقدمه

سیستم‌های ترکیب طبقه‌بندها[1] یکی از چهار مسیر پیشگام در حوزهٔ یادگیری ماشین می باشد *(Dietterich, 1997)*. درحقیقت استفاده از سیستم‌های شورایی[2] از طبیعت انسان در استفاده از نظرات مختلف برای تصمیم‌گیری‌های مهم الهام گرفته است. نظر افراد مختلف وزن داده شده و سپس ترکیب می شوند تا به نتیجهٔ نهایی حاصل شود *(Polikar, 2006)*. بهبود کارایی حاصل از ترکیب طبقه‌بندها *(Rokach, 2010)* موجب رشد روزافزون استفاده از این سیستم‌ها در حوزه‌های کاربردی بسیاری، ازجمله پزشکی *(Das and Sengur, 2010)*، بیوانفورماتیک *(Liu, et al., 2010)*، موضوعات مالی *(Hsieh and Hung, 2010)*، امنیت *(Kim and Kang, 2010)* و ... شده است. یک سیستم ترکیب طبقه‌بندها از دو قسمت اصلی طراحی طبقه‌بندهای پایه و به کارگیری قاعدهٔ ترکیب مناسب تشکیل شده است *(Kuncheva, 2004)*. یکی از پارامترهای مؤثر در بخش اوّل سیستم ترکیبی، ایجاد گوناگونی[3] بین طبقه‌بندهای پایه است *(Cunningham and Carney, 2000; Chandra and Yao, 2004)*. اهمیت این پارامتر به حدّی است که اگر طبقه‌بندهای پایه، مشابه باشند، هیچ بهبودی در کارایی چرخهٔ ترکیب بدست نخواهد آمد *(Tsymbal, et al., 2005)*. منظور از ایجاد گوناگونی بین طبقه‌بندها این است که راه‌کارهایی اتخاذ شود تا طبقه‌بندهای پایه خطاهای متفاوتی داشته باشند؛ به این معنی که نمونه‌هایی از ورودی که یک طبقه‌بند در مورد آن‌ها با خطا، تصمیم‌گیری می‌کند با خطاهای طبقه‌بندهای پایهٔ دیگر مشابه نباشد. از این‌رو به‌طور دقیق‌تر به این پارامتر گوناگونی در خطا[4] گفته می‌شود *(Brown, 2004 , Brown, et al., 2005)*.

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

[1] Classifier Ensemble
[2] Ensemble System
[3] Diversity
[4] Error Diversity

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

شده است (Chen, 2008). از نقطه‌نظر وجود یا عدم وجود چرخهٔ یادگیری[1]، روش‌های ترکیب به دو گروه ۱- روش‌های ایستا[2] و ۲- روش‌های مبتنی بر یادگیری[3] تقسیم‌بندی می‌شوند (Kuncheva, 2004). در روش‌های ترکیب ایستا، بعد از این که هر یک از طبقه‌بندهای پایه، آموزش دیدند نیازی به انجام چرخهٔ یادگیری برای ترکیب خروجی‌ها نیست. روش‌های میانگین‌گیری[4]، رأی اکثریت[5] و کلیشهٔ تصمیم[6] (Kuncheva, et al., 1999؛ Kuncheva, 2001)، از جمله روش‌های ترکیب ایستا محسوب می‌شوند. امّا در گروه دیگر، برای تنظیم پارامترهای ترکیب طبقه‌بندهای پایه، چرخه‌ای مبتنی بر یادگیری لحاظ شده است.

روش‌های تعمیم انباره‌ای[7] (Wolpert, 1992) و اختلاط خبره‌ها[8] (Jacobs, et al., 1991)، از جملهٔ مهمترین روش‌های ترکیب مبتنی بر یادگیری به‌شمار می‌آیند. روش‌های کلیشهٔ تصمیم و تعمیم انباره‌ای به‌عنوان 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[9] است که با ساختن ماتریس نمایهٔ تصمیم[10] از خروجی همهٔ طبقه‌بندهای پایه و مقایسهٔ 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 ساخته می‌شود و سپس با استفاده از معیار فاصله‌ای، میزان شباهت آن با ماتریس کلیشهٔ تصمیم هر طبقه،که نمایندهٔ آن طبقه محسوب می‌شود، محاسبه می‌گردد. درنهایت دادهٔ ورودی به طبقه‌ای منتسب می‌شود که بیش‌ترین میزان شباهت بین ماتریس نمایه تصمیم با ماتریس کلیشهٔ تصمیم آن طبقه برقرار باشد.

روش تعمیم انباره‌ای ازجمله روش‌های ترکیب مبتنی بر یادگیری است (Wolpert, 1992). در این روش ابتدا طبقه‌بندهای پایه به‌صورت مستقل روی مسأله آموزش می‌بینند و سپس خروجی طبقه‌بندهای لایهٔ اوّل در قالب مجموعه‌ای دیگر جمع‌آوری می‌شود. درواقع به‌ازای هر نمونه ورودی اصلی، خروجی طبقه‌بندهای پایه به‌عنوان جایگزینی برای نمایش الگوی آن ورودی لحاظ‌شده و به طبقه‌بند دیگری در لایهٔ دوم داده می‌شود. طبقه‌بند لایهٔ دوم با گرفتن خروجی طبقه‌بندهای پایهٔ لایهٔ اوّل به‌عنوان ورودی و انجام چرخهٔ یادگیری، تصمیم نهایی را اتخاذ می‌کند. جزییات 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 مرحلهٔ طراحی پایه، به دنبال ایجاد گوناگونی در طبقه‌بندهای پایه هستند (Brown, 2004).

راه‌های مختلفی برای ایجاد گوناگونی در خطا پیشنهاد شده است که از آن جمله می‌توان به استفاده از روش‌های یادگیری متفاوت، گوناگونی در بازنمایی الگوی[11] ورودی و گوناگونی در مجموعهٔ یادگیری[12] اشاره کرد(Kuncheva, 2004).

روش یادگیری مبتنی بر ایجاد همبستگی منفی یا به‌صورت خلاصه، یادگیری همبستگی منفی[13] (Liu and Yao, 1999) از جمله روش‌هایی است که به‌طور ضمنی یادگیری طبقه‌بندهای پایه را متفاوت می‌کند و از این طریق طبقه‌بندهای گوناگون[14] می‌سازد. در این روش از شبکه‌های عصبی به‌عنوان طبقه‌بندهای پایه استفاده می‌شود. این روش با اضافه کردن اصطلاح جریمه[15] ای به تابع خطای ترکیب شبکه‌های عصبی، موجب می‌شود که طبقه‌بندهای عصبی در حین یادگیری برای کاهش خطای خود، خروجی‌های خود را تا حدّی 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.

[1] Learning Process
[2] Static
[3] Learning-Based
[4] Averaging
[5] Majority Voting
[6] Decision Template
[7] Stacked Generalization
[8] Mixture of Experts
[9] Stable
[10] Decision Profile
[11] Different Representation
[12] Different Training Set
[13] Negative Correlation Learning
[14] Diverse Classifiers
[15] Penalty Term

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

برای این تحقیق یک سیستم ترکیبی در نظر گرفته شده است که در بخش اوّل از یادگیری همبستگی منفی در طراحی و چرخهٔ یادگیری طبقه‌بندهای پایه استفاده می‌کند. این وضعیت با حالتی که طبقه‌بندها به‌صورت مستقل[1] (بدون استفاده از روش همبستگی منفی) آموزش می‌بینند مقایسه شده است. در بخش دوم سیستم ترکیبی از دو روش ترکیبی کلیشهٔ تصمیم و تعمیم انباره‌ای به‌عنوان نماینده‌های دو گروه اصلی ترکیب استفاده شده و تأثیر استفاده از یادگیری همبستگی منفی بر کارایی این دو روش بررسی شده است.

ادامهٔ 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 ایدهٔ پیشنهادی این تحقیق ارائه شده است. نتایج آزمایش‌ها بر روی مجموعه‌داده‌های 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 طبقه‌بندهای عصبی

در این فصل نحوهٔ عملکرد دو روش متداول ترکیب طبقه‌بندهای عصبی شامل کلیشهٔ تصمیم و تعمیم انباره‌ای ارائه شده است. یکی از مزیت‌های عمدهٔ این دو روش در مقایسه با روش‌های دیگر ترکیب ازجمله 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 آن‌جا که خروجی شبکهٔ عصبی به‌صورت تخمین احتمال پسین تعلّقِ داده به طبقهٔ متناظر قابل تعبیر است (*Richard and Lippmann, 1991*) این دو روش با بهره‌گیری از اطّلاعات احتمالی تمام بردار خروجی شبکه‌های عصبی پایه، کارایی بهتری را از روش‌های ترکیب دیگر دارند.

۲-۱- کلیشهٔ تصمیم

در این روش ابتدا طبقه‌بندهای پایه به‌صورت مستقل از هم روی مجموعهٔ یادگیری[2] آموزش می‌بینند. روش کلیشهٔ تصمیم بر پایهٔ ساخت ماتریس‌های کلیشهٔ و نمایهٔ تصمیم و مقایسهٔ آن‌ها کار می‌کند (*Kuncheva, et al., 1999, Kuncheva, 2001*). نحوهٔ کارکرد روش کلیشهٔ تصمیم به این ترتیب است که به‌ازای ورودی سیستم x، ماتریس نمایهٔ تصمیم از روی بردارهای خروجی همهٔ طبقه‌بندهای پایهٔ ساخته می‌شود. ماتریس کلیشهٔ تصمیم به‌ازای هر یک از طبقه‌های مسأله ساخته شده، به نحوی که کلیشهٔ تصمیم هر طبقه بیان‌گر میانگین ماتریس‌های نمایهٔ تصمیم ورودی‌های مربوط به آن طبقه است. برای طبقه‌بندی داده آزمون[3]، پس از ساخت ماتریس نمایهٔ تصمیم این ماتریس با ماتریس‌های کلیشهٔ تصمیم همهٔ طبقه‌ها مقایسه می‌شود. برای مقایسه با درنظر گرفتن معیار فاصله‌ای، شباهت نمایهٔ تصمیم با کلیشه‌های تصمیم همهٔ طبقه‌ها سنجیده می‌شود. این مقدار شباهت می‌تواند به‌عنوان تخمینی از احتمال تعلق داده ورودی به هر یک از کلاس‌های مسأله تعبیر شود. درنهایت داده ورودی به طبقه‌ای با بیش‌ترین میزان شباهت نسبت داده می‌شود. در ادامه روش کلیشهٔ تصمیم را به‌صورت دقیق و با فرمول‌بندی ریاضی شرح خواهیم داد.

فرض کنید L طبقه‌بند و C طبقه داشته باشیم و مجموعهٔ W, D به‌ترتیب بیان‌گر مجموعهٔ طبقه‌بندها و مجموعهٔ طبقه‌ها باشد:

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

هر طبقه‌بند D_i به‌ازای دادهٔ ورودی x یک بردار خروجی به‌صورت:

$$D_i(x)=\{d_{i,1}(x)...d_{i,c}(x)\}$$

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

ماتریس نمایهٔ تصمیم از زیر هم قرار گرفتن بُردارهای خروجی L طبقه‌بند پایه به‌ازای ورودی x ساخته می‌شود:

$$DP(x)=\begin{pmatrix} d_{1,1} & \cdots & d_{1,C} \\ \vdots & d_{k,s} & \vdots \\ d_{L,1} & \cdots & d_{L,C} \end{pmatrix} \qquad (۱)$$

که مشابه قبل، در ماتریس نمایهٔ تصمیم $d_{k,s}(x)$ امتیاز تعلق الگوی x به کلاس w_s است که توسط طبقه‌بند D_k تخمین زده شده است.

حال نحوهٔ ساخت ماتریس‌های کلیشهٔ تصمیم را ارائه می‌کنیم. ماتریس DT_i، کلیشهٔ تصمیم کلاس iاُم، با میانگین‌گیری از درایه‌های نظیر به نظیر ماتریس‌های نمایهٔ تصمیم داده‌های طبقه iاُم ایجاد می‌شود. بیان ریاضی تشکیل ماتریس $DT_i(x)= [dt_i(k,s)(x)]$ به‌صورت رابطهٔ زیر است:

[1] Independent
[2] Training Set
[3] Test data

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

$$dt_i(k,s)(x) = \frac{\sum_{j=1}^{N} Ind(x_j, w_i) dp_{k,s}(x_j)}{\sum_{j=1}^{N} Ind(x_j, w_i)} \qquad (۲)$$

$$k = 1,\ldots,L \quad s = 1,\ldots,C$$

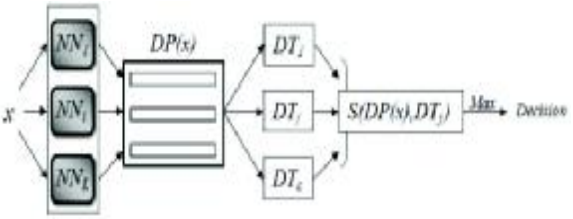
که در آن N، تعداد اعضای مجموعهٔ یادگیری و تابع $Ind(x_j,w_i)$ برای الگوی x_j متعلق به کلاس w_i یک و در غیر این‌صورت صفر است. پس از آنکه ماتریس کلیشهٔ تصمیم ساخته شد، به‌منظور تعیین عضویت دادهٔ آزمون، در ابتدا با توجّه به خروجی طبقه‌بندها، ماتریس نمایهٔ تصمیم در مورد الگوی ورودی تشکیل شده و سپس بر مبنای شباهت ماتریس نمایهٔ تصمیم با ماتریس کلیشهٔ تصمیم طبقه‌ها، الگوی مورد نظر طبقه‌بندی می‌شود. به‌منظور تعیین شباهت[1] از معیارهای متفاوتی استفاده شده است. یکی از این معیارها فاصله اقلیدسی طبق رابطه زیر است:

$$S(DT_i, DP(x)) = 1 - \frac{1}{LC}\sum_{k=1}^{L}\sum_{s=1}^{C}\sqrt{\left|dt_i(k,s)(x) - dP_{(k,s)}(x)\right|} \qquad (۳)$$

که تابع S میزان شباهت ماتریس نمایهٔ تصمیم ورودی $DP(x)$ با کلیشهٔ تصمیم طبقهٔ i، DT_i را مشخّص می‌کند. و درنهایت دادهٔ ورودی x به طبقهٔ m با بیش‌ترین میزان شباهت نسبت داده می‌شود:

$$m = \arg\max_i \left(S\left(DT_i, DP(x)\right)\right) \qquad (۴)$$

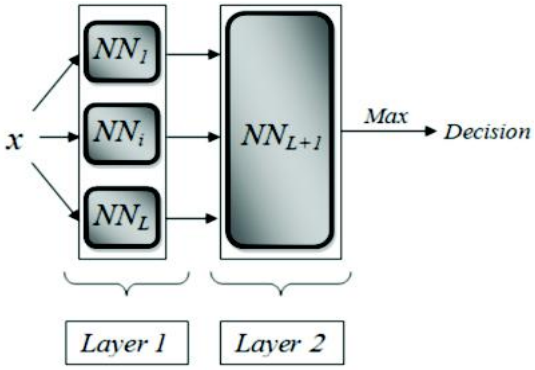
(تصویر ۱) شمای کلی از فرآیند طبقه‌بندی دادهٔ آزمون را در سیستم ترکیبی کلیشهٔ‌تصمیم را نشان می دهد:



(شکل ۱): شمای کلی عملکرد روش کلیشهٔ تصمیم در طبقه‌بندی دادهٔ آزمون. در این شکل NN_i نمادی از طبقه‌بند عصبی *i*اُم است.

۲-۲- روش تعمیم انباره‌ای

روش تعمیم انباره‌ای روشی مبتنی بر یادگیری برای ترکیب طبقه‌بندهاست (Wolpert, 1992). ساختار روش تعمیم انباره‌ای از دو سطح تشکیل شده است. در سطح اوّل، طبقه‌بندهایی قرار دارند که روی داده‌های مجموعهٔ یادگیری به‌صورت مستقل آموزش می‌بینند. پس از اتمام آموزش، خروجی طبقه‌بندهای لایهٔ اوّل به‌ازای تمام داده‌های مجموعهٔ یادگیری، جمع‌آوری شده و در مجموعه‌ای جدید قرار می‌گیرد. درواقع به‌ازای هر نمونهٔ ورودی اصلی، خروجی طبقه‌بندهای پایه به‌عنوان جایگزینی برای نمایش الگوی آن ورودی لحاظ شده و درواقع طبقه‌بندهای لایهٔ اوّل را می‌توان به‌عنوان تبدیلی غیرخطّی[2] برای تغییر فضای ورودی درنظرگرفت. خروجی طبقه‌بندهای لایهٔ اوّل به شبکهٔ عصبی دیگری در لایهٔ دوم داده می‌شود. به این ترتیب، اگر مشابه قبل فرض کنیم L طبقه بند و C طبقه داشته باشیم، در این روش طبقه‌بند عصبی لایهٔ دوم شبکه‌ای با $L*C$ ورودی و C خروجی خواهد بود. شبکهٔ عصبی لایهٔ دوم با گرفتن خروجی طبقه‌بندهای لایهٔ اوّل به‌عنوان ورودی، مورد آموزش قرار می‌گیرد تا تصمیم نهایی را اتخاذ کند. شکل زیر به‌صورت نمادین ساختار روش تعمیم انباره‌ای را نشان می‌دهد.



(شکل ۲): شمای کلی عملکرد روش ترکیب تعمیم انباره‌ای در طبقه‌بندی دادهٔ آزمون. در این شکل NN_i نمادی از طبقه‌بند عصبی *i*اُم است.

۳- یادگیری مبتنی بر ایجاد همبستگی منفی

اکثر روش‌های ترکیب شبکه‌های عصبی، شبکه‌های پایه را به‌صورت توالی پی‌درپی[3] و یا به‌صورت هم‌زمان[4] 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 به‌صورت 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 به‌صورت هم‌زمان انجام می‌دهد.

این روش یک اصطلاح جریمهٔ همبستگی[5] به تابع خطای هر یک از شبکه‌های پایه اضافه می‌کند. در طول فرآیند یادگیری تمام طبقه‌بندهای پایه با این دورهٔ جریمهٔ تابع خطا با یکدیگر ارتباط خواهند داشت.

[1] Similarity

[2] Nonlinear Transformation
[3] Sequential
[4] Synchronize
[5] Correlation Penalty

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

تابع خطای شبکهٔ iاُم، E_i، به‌ازای ورودی n در روش یادگیری همبستگی منفی به این شکل تعریف می‌شود:

$$E_i(n)=\frac{1}{2}(y_i(n)-t(n))^2+\lambda P_i(n) \qquad (۵)$$

که $y_i(n)$ و $t(n)$ به‌ترتیب خروجی شبکهٔ عصبی iاُم و خروجی مطلوب و $P_i(n)$ تابع جریمهٔ همبستگی به‌ازای ورودی nام است.

تابع همبستگی P_i به شکل زیر تعریف می‌شود:

$$P_i(n)=\frac{1}{2}\left(y_i(n)-\overline{y}(n)\right)^2 \qquad (۶)$$

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

با لحاظ کردن این تابع خطا، هر شبکهٔ عصبی در ضمن کاهش خطای خود، سعی می‌کند که پارامتر P_i را نیز کمینه نماید. پارامتر $0 \le \lambda \le 1$ برای تنظیم توان[1] تابع جریمه استفاده شده است. کمینه‌کردن اصطلاح ۵ مستلزم آن است که که هر شبکه علاوه‌بر کاهش خطای خود، همبستگی‌اش با سایر شبکه‌های عصبی را نیز کاهش دهد. با تنظیم پارامتر توان تابع جریمه می‌توان مقدار این کاهش را تا حدّی 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 نظری دیگر، وجود این اصطلاح جریمهٔ همبستگی باعث می‌شود که شبکه‌های پایه در حل مسأله با یکدیگر همکاری کرده و هرکدام جنبه‌ها یا قسمت‌های مختلفی از مسأله را مورد بررسی قرار می‌دهند(Liu and Yao, 1999).

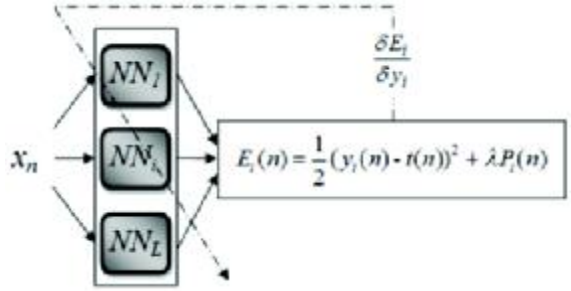
در روش یادگیری‌همبستگی منفی از روش پس‌انتشارخطا در حالت الگوبه‌الگو برای اصلاح و هم‌گرایی مقادیر وزن‌های شبکه‌های عصبی استفاده می‌شود. بدین منظور مشتق جزیی تابع خطای E_i نسبت به خروجی y_i به‌ازای ورودی nاُم به این شکل محاسبه می‌شود:

$$\frac{\delta E_i(n)}{\delta y_i(n)}=y_i(n)-t(n)+\lambda(y_i(n)-\overline{y}(n)) \qquad (۷)$$

و اصلاح وزن‌های شبکه‌های پایهٔ سیستم ترکیبی بر اساس این فرمول به‌صورت هم‌زمان انجام می‌شود.

نحوهٔ عملکرد روش یادگیری همبستگی منفی در شکل زیر به‌صورت نمادین نمایش داده شده است.

[1] Strength



(شکل ۳): شمای فرآیند یادگیری طبقه‌بندهای عصبی پایه در یادگیری همبستگی منفی. در این شکل NN_i نمادی از طبقه‌بند عصبی iاُم است

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

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

استفاده از طبقه‌بندهای عصبی گوناگون[2] می‌تواند کارایی سیستم ترکیب طبقه‌بندها را افزایش دهد. درصورتی ایجاد گوناگونی بین طبقه‌بندهای پایه موجب بیش‌ترین تأثیر بر کارایی ترکیب خواهد شد که میزان گوناگونی اعمال شده با توجّه به مسأله مورد نظر قابل کنترل باشد (Nabavi, 2004؛ Ghaderi, 2000؛ Kittler and Roli, 2000).

روش یادگیری همبستگی منفی با لحاظ‌کردن پارامتر تنظیم توان تابع جریمهٔ، λ، این قابلیت را داراست. به همین دلیل روش ارائه شده در این مقاله، در مرحلهٔ اوّل سیستم ترکیبی از این روش برای آموزش و گوناگون کردن شبکه‌های عصبی پایه استفاده می‌کند. در مرحلهٔ بعدی دو روش کلیشهٔ تصمیم و تعمیم انباره‌ای به‌عنوان 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 نقطه‌نظر دیگری هم قابل بررسی است. تاکنون برای ترکیب طبقه‌بندهای عصبی حاصل از یادگیری همبستگی منفی از روش‌های

[2] Diverse Neural Classifiers

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

میانگین‌گیری و رأی اکثریت استفاده می‌شد که در این تحقیق استفاده از روش‌های کاراتر کلیشهٔ 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 اوّل 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 کلیشهٔ تصمیم و تعمیم انباره‌ای روش‌های بهتری برای ترکیب طبقه‌بندهایی با همبستگی منفی هستند، مقایسهٔ دیگری انجام شده است. در این حالت کارایی دو روش ترکیب پیشنهادی با روش‌های مورد استفادهٔ پیشین شامل میانگین‌گیری و رأی اکثریت مقایسه می‌شود.

۴- نتایج آزمایش‌ها

پنج مجموعه‌دادهٔ آزمون طبقه‌بندی[1] از بانک داده UCI *(Frank and Asuncion, 2010)* و ELENA (النا) در این آزمایش استفاده شده که توضیحات مختصری از اطّلاعات آنها در ذیل آورده می‌شود:

۱. تصاویر ماهواره‌ای[2]

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 همهٔ مقادیر از ویژگی‌های جالب این مجموعه‌داده است.

۲. وسایل نقلیه[3]

این مجموعه‌داده از تصاویر دوبعدی انواع مختلفی از وسایل نقلیه با استخراج ویژگی هندسی از تصویر آنها ساخته شده و شامل ۹۴۶ نمونه از چهار وسیلهٔ نقلیهٔ 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 مسأله به‌طور تقریبی با هم برابر است.

۳. دیابت[4]

یک مجموعه‌دادهٔ دو طبقه است که شامل ۷۶۸ نمونه است که ۵۰۰ نمونهٔ آن مربوط به کلاس اوّل با برچسب مثبت‌بودن آزمایش دیابت و ۲۶۸ نمونهٔ آن مربوط به طبقهٔ دوم با برچسب منفی‌بودن آزمایش دیابت است. بُردار ویژگی نمونه‌ها یک بُردار ۸ بُعدی از مشخّصات هر فرد است.

۴. سرطان پستان[5]

سرطان پستان یک مجموعه‌دادهٔ دو طبقه، شامل ۶۸۳ نمونه است . ۴۴۴ نمونهٔ آن مربوط به طبقهٔ سرطان بدخیم و ۲۳۹ نمونهٔ آن مربوط به طبقهٔ سرطان خوش‌خیم است. بُردار و یژگی نمونه‌ها یک بُردار ۱۰ بُعدی است.

۵. امواج خورشیدی[6]

این مجموعه‌دادهٔ طبقه‌بندی بر اساس تمایز نحوهٔ 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 نحوهٔ 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 اوّل و ۹۷ نمونه از کلاس دوم) که بُردار اطّلاعات هر نمونه شامل ۶۰ ویژگی کمّی است.

اطّلاعات کمّی این پنج مجموعه‌دادهٔ آزمون طبقه‌بندی به‌صورت خلاصه در (جدول ۱) آورده شده است.

(جدول ۱): اطّلاعات مربوط به مجموعه‌داده‌های آزمون طبقه‌بندی

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

در آزمایش‌های این مقاله از پنج شبکهٔ عصبی پرسپترون چندلایه[7] با یک لایهٔ مخفی[8] به‌عنوان

[1] Classification Benchmark
[2] Satelite Image
[3] Vehicle
[4] Pima Indian Diabets
[5] Breast Cancer
[6] Sonar
[7] Multi-Layer Perceptrons
[8] Hidden Layer

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

طبقه‌بندهای پایه استفاده شده است. اطّلاعات ساختار سیستم‌های ترکیبی مورد استفاده برای طبقه‌بندی هر مجموعه‌داده در (جدول ۲) آورده شده است. این اطّلاعات شامل تعداد و ساختار هر شبکهٔ عصبی پایه و نیز ساختار شبکهٔ عصبی ترکیب‌کنندهٔ مورد استفاده در روش تعمیم انباره‌ای است. برای محاسبهٔ کارایی روش‌های مورد بررسی از ایدهٔ اعتبارسنجی تکراری با زیرمجموعه‌های تصادفی[1] استفاده شده است، به این نحو که مجموعه‌داده در هر بار تکرار آزمون، به سه زیرمجموعه شامل مجموعهٔ یادگیری، مجموعهٔ اعتبارسنجی[2] و مجموعهٔ 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. اطّلاعات ساختاری به‌صورت [x:y:z] (n) ارائه شده که n نشان‌گر تعداد شبکهٔ پایه و z,y,x به ترتیب بیان‌گر تعداد نرون در لایهٔ ورودی، میانی و خروجی شبکه‌های عصبی است.

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

مجموعه یادگیری برای هم‌گرایی پارامترهای ساختار شبکهٔ عصبی استفاده و با بهره‌گیری از مجموعهٔ اعتبارسنجی و ایدهٔ نقطهٔ توقف زودهنگام[3] از مشکل انطباق مفرط[4] جلوگیری می‌شود. لازم به ذکر است که به‌دلیل لحاظ‌کردن زیرمجموعهٔ تاحدودی اندک از مجموعهٔ داده، به‌عنوان مجموعهٔ یادگیری، درحدود ۳۰٪ مشابه شرایط (*Kuncheva, et al., 1999*)، استفاده از مجموعهٔ اعتبارسنجی برای جلوگیری از مشکل مذکور ضروری است. در پایان فرآیند یادگیری، سیستم ترکیب شبکه‌های عصبی به‌دست آمده روی مجموعهٔ آزمون اعمال شده و نرخ کارایی محاسبه می‌شود. نتایج گزارش شده، حاصل میانگین ده بار اجرای هر یک از روش های مورد بررسی با استفاده از فرآیند اعتبارسنجی یاد شده است. شایان توجّه است که شرایط مجموعه یادگیری اندک[5] برای نشان‌دادن توانایی تعمیم ساختار ترکیب شبکه‌های عصبی اتخاذ شده است. به‌دلیل کوچک بودن حجم مجموعهٔ 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*). نحوهٔ تعیین ساختار شبکه‌های پایه به این ترتیب بوده است که در ابتدا تعداد بهینهٔ نرون‌های لایهٔ میانی یک شبکهٔ 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 بهینهٔ شبکهٔ عصبی ترکیب‌کننده در روش تعمیم انباره‌ای نیز بر اساس آزمودن تعداد مختلف نرون‌های لایهٔ میانی و انتخاب وضعیت برتر بر اساس کارایی بیشینه، روی مجموعهٔ اعتبارسنجی انجام شده است.

شبکه‌های عصبی ساختار ترکیب با نرخ یادگیری[6] ۰.۱ روی مجموعه یادگیری آموزش دیده‌اند. در این تحقیق پارامتر توان جریمهٔ همبستگی به‌ازای مقادیر مختلف در بازهٔ [۱:۰.۱:۰] آزموده شده و به‌ازای هر مسأله بیش‌ترین کارایی طبقه‌بندی حاصل از مقدار بهینهٔ آن در مجموعهٔ اعتبارسنجی، در جداول گزارش شده است.

برای بررسی تأثیر ایجاد گوناگونی ناشی از یادگیری همبستگی منفی بر کارایی روش‌های ترکیب کلیشهٔ تصمیم و تعمیم انباره‌ای آزمایش‌هایی انجام شده است که در حالت اوّل 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 کلیشهٔ تصمیم و تعمیم انباره‌ای ترکیب شده‌اند که نتایج به‌ترتیب در جداول ۳ و ۴) آورده شده است.

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

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

[1] Repeated Random Sub-Sampling Validation
[2] Validation Set
[3] Early Stopping point
[4] Over-Fitting
[5] Small Sample Size
[6] Learning Rate

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

همان‌طور که در نتایج (جدول ۳) مشخّص است، با استفاده ازیادگیری همبستگی منفی توانسته است در مقایسه با حالت یادگیری مستقل طبقه‌بندهای 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 طبقه‌بندهای پایه.

مجموعه داده	میانگین کارایی مجزای ۵ طبقه بند پایه	یادگیری مستقل + 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
سرطان 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 صحّت طبقه‌بندی روش ترکیب تعمیم انباره‌ای را نیز به‌طور قابل ملاحظه‌ای نسبت به یادگیری مستقل طبقه‌بندهای پایه افزایش داده است.

همان‌طور 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 مقایسهٔ کارایی روش‌های پیشنهادی با روش‌های مورد استفاده پیشین در (جدول ۵) آورده شده است.

(جدول ۵): نتایج مربوط به مقایسهٔ 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 مستقل + میانگین گیری	یادگیری همبستگی منفی + میانگین گیری	یادگیری همبستگی منفی + رأی اکثریت	یادگیری همبستگی منفی + کلیشهٔ تصمیم	یادگیری همبستگی منفی + تعمیم انباره‌ای
تصاویر ماهواره‌ای	۶۳/۱	۶۴/۸	۶۵	۶۷/۶	۶۶/۳
وسایل نقلیه	۶۷/۹	۶۸/۷	۶۹/۴۸	۷۱/۵	۷۳/۲
دیابت	۶۸/۳	۷۰/۶۵	۶۹/۴	۷۳/۲۹	۷۲/۸۲
سرطان پستان	۸۸/۰۴	۸۹/۱۱	۸۹/۴	۹۲/۰۷	۹۲/۸۴
امواج خورشیدی	۵۹/۳۷	۶۲/۷	۶۲/۳۱	۶۶/۱	۶۵

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

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 (جداول ۴،۳و۵) مورد مقایسه قرار گرفت. نتایج مقایسه نشان می‌دهد که در وضعیت ترکیب شبکه‌های مستقل، کلیشهٔ تصمیم در ۸۰٪ موارد عملکرد بهتری داشته است. امّا 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 ایستا در مقابل 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 مسأله با یکدیگر همکاری کرده و هرکدام جنبه‌ها یا قسمت‌های مختلفی از مسأله 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 صحّت طبقه‌بندی به مراتب بالاتری نسبت به روش‌های پیشین بوده‌اند.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

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

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

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

http://archive.ics.uci.edu/ml/datasets/Statlo g+%28Vehicle +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.

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 Compution 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

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]

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 رشتهٔ هوش مصنوعی در دانشگاه آزاد واحد علوم تحقیقات در سال ۱۳۸۱ دریافت نمود. زمینه‌های مورد علاقهٔ وی، هوش مصنوعی، سیستم‌های بیومتریک و سخت‌افزار کامپیوتر می‌باشد.

نشانی رایانامک ایشان عبارتست از:

kargarnejad@azad.ac.ir
az_micro@yahoo.com



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

نشانی رایانامک ایشان عبارتست از:

s.masoudnia@gmail.com
masoudnia@alumni.ut.ac.ir



امیرحسین کاشفی در سال ۱۳۸۶ مدرک کارشناسی خود را در رشتهٔ مهندسی کامپیوتر از دانشگاه آزاد اسلامی واحد تهران جنوب دریافت کرد و مدرک کارشناسی ارشد خود را در رشتهٔ علوم کامپیوتر در دانشگاه تهران در سال ۱۳۸۹ دریافت نمود. زمینه‌های مورد علاقهٔ وی، یادگیری ماشین و تشخیص الگو، داده‌کاوی، ترکیب طبقه‌بندها و اصول ترکیبیات می‌باشد.

نشانی رایانامک ایشان عبارتست از:

amirhosein.kashefi@gmail.com
a.kashefi@alumni.ut.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-18]