

افزایش نرخ کارایی طبقه‌بندی با استفاده از تجمیع ویژگی‌های مؤثر روش‌های مختلف ترکیب شبکه‌های عصبی

جواد محمدزاده^۱، سعید مسعودنیا^۲، علی آرانی^۳

^۱ دانشگاه آزاد اسلامی، واحد کرج، ^۲ دانشگاه آزاد اسلامی، واحد تهران مرکز و باشگاه پژوهشگران جوان و

^۳ دانشگاه تربیت دبیر شهید رجایی

چکیده:

روش‌های یادگیری همبستگی منفی و اختلاط خبره‌ها، به‌عنوان دو روش معروف ترکیب شبکه‌های عصبی، از توابع خطای منحصر به فرد و البته متفاوتی برای آموزش شبکه‌های پایه، به‌صورت هم‌زمان استفاده کرده، که شبکه‌هایی با همگرایی منفی تولید می‌کنند. در این مقاله ویژگی‌های مختلف این دو روش را مرور و نقاط قوت و ضعف آنها را در مقایسه با یکدیگر بررسی می‌کنیم. بررسی خصوصیات این دو روش در مقایسه با یکدیگر نشان داد که آن‌ها ویژگی‌های متفاوت و البته مکملی نسبت به هم دارند؛ به نحوی که اگر بتوان سیستمی ترکیبی شامل ویژگی‌های مثبت هر دو روش طراحی کرد، به‌احتمال کارایی بهتری از روش‌های پایه خود داشته باشد. در این مقاله ایده‌ای برای ترکیب ویژگی‌های این دو روش پیشنهاد کرده‌ایم. در این روش، قابلیت پارامتر کنترلی روش یادگیری همبستگی منفی به تابع خطای روش اختلاط خبره‌ها افزوده شده، که این روش را قادر می‌سازد تعادل بهینه‌ای را در توازن بایاس-واریانس-کوواریانس ایجاد و کارایی را افزایش دهد. روش ترکیبی پیشنهاد شده، در چند مسألهٔ آزمون پیش‌بینی و طبقه‌بندی با روش‌های پایهٔ اختلاط خبره‌ها و یادگیری همبستگی منفی مورد مقایسه قرار گرفته است. نتایج آزمایش‌ها نشان داده است که روش ترکیبی پیشنهاد شده، با حفظ نقاط قوت و کاهش ضعف‌های روش‌های پایه، توانسته کارایی را به‌طور قابل ملاحظه‌ای نسبت به آنها افزایش دهد.

واژگان کلیدی: طبقه‌بندی، ترکیب شبکه‌های عصبی، یادگیری همبستگی منفی و اختلاط خبره‌ها.

۱- مقدمه

ترکیب شبکه‌های عصبی (Rokach, 2010b) روشی برای بهبود کارایی در مسائل پیش‌بینی و طبقه‌بندی، به‌خصوص در حل مسائل پیچیده‌ای با وجود تعداد محدود نمونه، بردار ویژگی‌هایی با ابعاد بالا و یا دسته‌هایی با هم‌پوشانی زیاد است (Ghaemi et al., 2010; Ebrahimipour et al., 2011; Rokach, 2010a). روش‌های ترکیب از دو جزء اصلی تشکیل شده‌اند: ۱. قسمت آموزش شبکه‌های پایهٔ سیستم ترکیبی ۲. قسمت ترکیب خروجی‌ها. تحقیقات تئوری و نیز تجربی نشان می‌دهد که کارایی سیستم شبکه‌های عصبی، زمانی بهینه است که بین شبکه‌های پایه، همبستگی منفی وجود داشته باشد. روش‌های مختلفی برای ایجاد همبستگی منفی میان شبکه‌های پایه پیشنهاد شده است که از آن جمله می‌توان به وزن‌دهی اولیه به‌صورت تصادفی، استفاده از شبکه‌هایی با ساختارهای متفاوت، به‌کارگیری

الگوریتم‌های متفاوت یادگیری و متفاوت ساختن مجموعه‌های یادگیری اشاره کرد. در مقاله (Islam et al., 2008b) اشاره شده که متفاوت کردن مجموعه‌های یادگیری شبکه‌های پایه از بقیه روش‌های مورد استفاده در تولید شبکه‌هایی با همبستگی منفی، مؤثرتر عمل می‌کند.

دو روش ترکیب شبکه‌های عصبی که به‌ترتیب شبکه‌های پایه را به‌صورت مستقل از هم و پی‌درپی آموزش می‌دهند و از ایدهٔ ایجاد مجموعه‌های یادگیری متفاوت به‌صورت صریح استفاده می‌کنند، روش کیسه‌ای کردن^۱ و تقویتی^۲ نام دارند. روش‌های یادگیری همبستگی منفی^۳ و اختلاط خبره‌های^۴ پایه، به‌عنوان روش‌های دیگری در ترکیب طبقه‌بندها با به‌کارگیری توابع خطای ویژه‌ای،

¹ Bagging

² Boosting

³ Negative Correlation Learning

⁴ Mixture of Experts

مبتنی بر معیار اطمینان برای ترکیب خروجی‌ها استفاده می‌کند. روش پیشنهادی آنها توانست روش قبلی را پشت سر گذاشته و کارایی بالاتری نسبت به آنها به دست آورد.

ایسلام^۴ و همکارانش در مقاله^۵ (Islam et al., 2008a)، روش یادگیری همبستگی منفی را در الگوریتم روش‌های تقویتی و کیسه‌کردن وارد کردند و بدین‌وسیله کارایی آنها را بهبود دادند. ایده این روش در ساختار پویا و قابل گسترش ترکیب شبکه‌های عصبی پیاده‌سازی شده، به طوری که علاوه بر روش یادگیری متداول و جدای از هم شبکه‌های پایه در دو روش تقویتی و کیسه‌کردن، بازه‌ای از فرآیند یادگیری شبکه‌های پایه نیز به یادگیری هم زمان مبتنی بر همبستگی منفی اختصاص داده شده است.

در ادامه، ویژگی‌های دو روش یادگیری همبستگی منفی و اختلاط خبره‌های پایه را بررسی و نقاط ضعف و قوت آنها را در مقایسه با یکدیگر مشخص کرده‌ایم. از آنجایی که نقاط قوت و ضعف این دو روش مکمل یکدیگر به نظر می‌رسند، سؤالی مطرح می‌شود که آیا جمع کردن ویژگی‌های این دو روش در ساختار یک روش ترکیبی مجتمع می‌تواند موجب بهبود کارایی شود یا خیر؟ با بررسی این سؤال، ایده‌ای برای ترکیب ویژگی‌های روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی ارائه کرده‌ایم. در روش پیشنهادی با استفاده از یادگیری همبستگی منفی مقادیر پارامترهای منظم‌سازی در روش اختلاط خبره‌ها تنظیم و به این ترتیب کارایی این روش بهبود یافته است.

۲- مروری بر روش‌های اختلاط خبره‌ها و یادگیری همبستگی منفی

در این بخش، روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی و ویژگی‌های این دو روش ترکیب شبکه‌های عصبی مرور می‌شود.

۲-۱- اختلاط خبره‌های پایه

مدل اختلاط خبره‌ها توسط جیکابز^۵ و همکارانش در مقالات (Jacobs et al., 1991) معرفی شد. در این مقالات توابع خطای مختلف برای استفاده به‌عنوان تابع خطای ترکیب شبکه‌های عصبی مورد آزمون قرار گرفته است. در این مقاله اشاره شده که محلی‌سازی خبره‌ها در نواحی مختلفی از

شبکه‌های پایه را به صورت هم‌زمان آموزش می‌دهند. در حالی که روش‌های کیسه‌ای کردن و تقویتی با تغییر توزیع احتمال انتخاب مجموعه یادگیری هر یک از خبره‌های پایه، صریحاً مجموعه‌های متفاوتی را برای شبکه‌های پایه لحاظ می‌کنند، روش‌های یادگیری همبستگی منفی و اختلاط خبره‌های پایه با به کارگیری توابع خطای ویژه‌ای، شبکه‌های پایه را به صورت ضمنی به یادگیری قسمت‌های متفاوتی از مجموعه یادگیری ترغیب می‌کنند (Rokach, 2010b). با توجه به نحوه ایجاد تفاوت در مجموعه‌های یادگیری، گروه اول را روش‌های صریح و گروه دوم را روش‌های ضمنی تقسیم فضای یادگیری می‌نامند. از آنجایی که این دو نوع روش، نقاط قوت و ضعف مختلف و در بعضی موارد مکملی دارند، تحقیقاتی سعی داشته‌اند تا ویژگی مکمل این روش‌ها را در یک سیستم ترکیبی جمع کنند، که مواردی از این تحقیقات در ادامه مرور خواهد شد.

واترهوس^۱ در مقاله^۱ (Waterhouse, 1997) ایده‌هایی برای ترکیب ویژگی‌های دو روش اختلاط خبره‌های پایه و روش تقویتی ارائه کرده است. او و همکارانش دو روش ارائه کردند تا نقاط ضعف هر دو روش را با به کارگیری ویژگی‌هایی از روش دیگری برطرف کنند. ایده اول به‌عنوان بهبودی بر روش اختلاط خبره‌ها قابل بررسی است. در این روش از ایده تقسیم فضای مبتنی بر روش تقویتی برای جهت‌دهی اولیه شبکه‌های پایه اختلاط خبره‌ها استفاده شده است. از آنجایی که روش تقویتی، فضای مسأله را بر اساس قابلیت شبکه‌های پایه در حل مسأله تقسیم‌بندی می‌کند، می‌توان این نحوه تقسیم فضا را برای جهت‌دهی اولیه شبکه‌های پایه اختلاط خبره‌ها لحاظ کرد. زیرا ویژگی محلی‌سازی مورد نیاز آن روش را برآورده می‌کند. ایده دوم به‌عنوان بهبودی بر روش تقویتی ارائه شده که در آن، از روش پویای شبکه میانجی برای ترکیب خروجی شبکه‌های پایه روش تقویتی استفاده شده است.

آونیملچ^۲ و اینراتر^۳ (Avnimelech and Intrator, 1999) ایده‌های کار واترهوس (Waterhouse, 1997) را گسترش و یک سیستم پویای ترکیب شبکه‌های عصبی را برای تجمیع ویژگی‌های دو روش اختلاط خبره‌های پایه و روش تقویتی پیشنهاد کردند. در مقاله آنها ابتدا نقاط قوت و ضعف این دو روش در مقایسه با یکدیگر بررسی شده است. در جهت بهبود روش‌های قبلی، آنها سیستم پویایی از ترکیب شبکه‌های عصبی ارائه کردند که از شبکه میانجی

¹ Waterhouse

² Avnimelech

³ Intrator

⁴ Islam

⁵ Jacobs

سوق می‌دهد که این امر بر مبنای نظر شبکه میانی با لحاظ کردن کارایی هر خبره صورت می‌گیرد.

مدل اختلاط خبره‌های پایه، ویژگی‌های جالبی دارد که آن را از سایر روش‌های ترکیب مجزا می‌کند. یکی از تمایزات این روش، ایده ترکیب پویای وزن دار خبره‌ها بر مبنای خبرگی آنها در زیر فضاهای مختلف مسأله است. در این مدل بر مبنای اصل تقسیم و غلبه، فضای پیچیده مسأله به تعدادی زیر فضای ساده‌تر بین خبره‌ها تقسیم می‌شود. در این مدل، برخلاف روش‌های دیگر ترکیب شبکه‌های عصبی، به جای نسبت‌دادن وزن‌های ثابت برای ترکیب خبره‌ها، یک شبکه میانی به سیستم ترکیب اضافه شده است که بر حسب ورودی و خبرگی محلی خبره‌ها در نواحی مختلف فضای مسأله، وزن‌های بهینه ترکیب شبکه‌های پایه را تخمین بزند (Masoudnia and Ebrahimpour, 2012). به دلیل این ویژگی‌های مهم، این روش در تحقیقات مختلف یادگیری ماشینی (Masoudnia et al., 2010; Ubeyli, 2009) و نیز در روش‌های پردازش الگو (Ebrahimpour et al., 2011; Ubeyli et al., 2010) بسیار مورد توجه قرار گرفته است.

۲-۲- یادگیری همبستگی منفی

به‌طور معمول در روش‌های مختلف ترکیب شبکه‌های عصبی، شبکه‌های پایه به‌صورت مستقل از هم مورد آموزش قرار می‌گیرند. یکی از معایب این روش‌ها فقدان ارتباط شبکه‌های پایه و همکاری میان آنها در حین فرآیند یادگیری است. یادگیری مستقل شبکه‌های پایه سیستم ترکیبی موجب می‌شود تا آنها نتوانند در حل مسأله به‌صورت مؤثری با هم همکاری کنند.

لیو و یائو^۱ در مقاله‌های (Liu and Yao, 1999a, b) روش یادگیری همبستگی منفی را معرفی کردند که در آن شبکه‌های عصبی به‌صورت هم‌زمان و با همکاری یکدیگر به حل مسأله می‌پردازند. این همکاری و ارتباط چندجانبه با لحاظ کردن عبارت خطای همبستگی در تابع خطای هر یک از آنها به‌دست آمده است. در این روش، تابع خطای شبکه عصبی نام ترکیب به این ترتیب است:

$$E_i = \frac{1}{2}(O_i - y)^2 + \lambda P_i \quad (3)$$

که O_i و y به ترتیب خروجی واقعی شبکه نام و خروجی مطلوب است. اولین عبارت در تابع خطای مذکور،

فضای مسأله و در نتیجه افزایش گوناگونی میان آنها موجب بهبود کارایی سیستم ترکیبی خواهد شد. بر مبنای این معیارها، در این مقاله جیکابز تابع خطای جدید برای ترکیب شبکه‌های عصبی معرفی می‌کند که بر مبنای احتمال تولید بردار خروجی مطلوب در مدل ترکیبی از گوسین‌ها کار می‌کند:

$$E = -\log \sum_j g_j \exp\left(-\frac{1}{2}(y - O_j)^2\right) \quad (1)$$

برای بررسی نحوه عملکرد این تابع خطا، مشتق آن نسبت به خبره نام بررسی شده است

$$\frac{\delta E}{\delta O_i} = - \left[\frac{g_i \exp\left(-\frac{1}{2}(y - O_i)^2\right)}{\sum_j g_j \exp\left(-\frac{1}{2}(y - O_j)^2\right)} \right] (y - O_i) \quad (2)$$

بر اساس مشتق تابع خطای سوم، اصلاح وزن هر خبره، مشابه تابع خطای دوم، بر مبنای خطای مجزای آن صورت می‌گیرد. امتیاز این تابع خطا نسبت به موارد قبل وجود ضریبی برای اصلاح وزن هر خبره است که مقدار این ضریب با کارایی نسبی آن خبره نیز متناسب است. این دو ویژگی تابع خطای سوم در کنار هم موجب محلی‌سازی هر خبره در محدوده زیر فضای اختصاصی خودش می‌شود. این تابع خطا با برطرف کردن نواقص توابع خطای اول و دوم موجب کارایی بهتری در مدل اختلاط خبره‌های پایه می‌شود (Jacobs et al., 1991).

همچنین، در این مدل ترکیبی یک شبکه میانی برای مدل‌سازی نحوه پخش و تقسیم فضای خبره‌ها به‌کار گرفته شده است. شبکه میانی در حین فرآیند یادگیری خود، میزان خبرگی هر شبکه عصبی در نواحی مختلف مسأله را آموزش دیده و نیز با دادن ضرایبی به میزان اصلاح وزن هر خبره، در نحوه محلی‌سازی آن دخالت می‌کند. قانون یادگیری و اصلاح وزن شبکه میانی به‌نحوی است که با فرض مدل اختلاط گوسین‌ها، فرآیند یادگیری، میزان درست‌نمایی فضای مسأله را در این مدل افزایش می‌دهد؛ به‌صورتی که هر خبره مسئول یکی از این اجزای ترکیب گوسین‌ها باشد. به این ترتیب شبکه میانی فضای مسأله را تقسیم و هر خبره را به سمت زیر فضای لحاظ شده برای آن

¹ Liu and Yao

براون در مقاله (Brown and Wyatt, 2003) نشان داد که روش یادگیری همبستگی منفی را می‌توان مشتق شده از نحوه خاصی از تجزیه ابهام^۳ به حساب آورد. تجزیه ابهام، به‌عنوان یکی از مهم‌ترین نتایج تئوری میسخت ترکیب یادگیرنده‌ها مطرح است. از این تجزیه، قابل اثبات است که میانگین مربع خطای ترکیب از میانگین مربع خطای شبکه‌های پایه ترکیب، به اطمینان کمتر است.

$$(O_{ens} - y)^2 = \sum_j g_j (O_j - y)^2 - \sum_j g_j (O_j - O_{ens})^2 \quad (5)$$

که در این رابطه g ضریب شبکه نام و O_{ens} ترکیب محدب خروجی شبکه‌های پایه است. تجزیه ابهام توجیه واضح و شفافی برای نحوه تأثیر میزان همبستگی بر کارایی ترکیب ارائه می‌کند. این تجزیه، خطای کلی ترکیب را به دو عبارت مستقل تجزیه می‌کند. عبارت اول میانگین وزن دار خطای شبکه‌های پایه سیستم ترکیبی است. عبارت دوم که عبارت ابهام نامیده شده، میزان گوناگونی شبکه‌های پایه سیستم ترکیبی را اندازه‌گیری می‌کند. همان‌طور که در قبل هم اشاره شد، به‌کارگیری ضریب λ این امکان را می‌دهد تا میزان تأثیر عبارت همبستگی در مقایسه با عبارت خطای یادگیرنده‌ها کنترل شود. تحت کنترل درآوردن میزان این تأثیر، منجر به ایجاد تعادل کمینه در توازن بین این دو عبارت می‌شود. توازن بین این دو عبارت در ادبیات موضوع ترکیب یادگیرنده‌ها، در اصطلاح، توازن بین دقت و گوناگونی^۴ نامیده شده است.

در مقاله (Hansen, 2000) ارتباط میان دو تجزیه مختلف خطا، یعنی تجزیه بایاس-واریانس-کوواریانس و تجزیه ابهام مورد بررسی قرار گرفته و نشان داده شده است که بخش‌های مختلف تجزیه اول در تناسب با بخش‌های تجزیه دوم قرار دارند. این ارتباط بین دو تجزیه، بیان‌گر آن است که ایجاد تعادل کمینه در توازن دقت-گوناگونی به ایجاد تعادل معادل در توازن بایاس-واریانس-کوواریانس منجر خواهد شد و برعکس، افزایش قابلیت تعمیم روش، نتیجه اصلی توازن این پارامترهاست.

۳- روش ارائه شده: اختلاط خبره‌هایی با همبستگی منفی

در این بخش، در ابتدا ویژگی‌های روش اختلاط خبره‌های پایه در مقایسه با روش یادگیری همبستگی منفی

³ Ambiguity


⁴ Accuracy-Diversity Tradeoff

تابع ریسک تجربی شبکه نام است. عبارت دوم P_i عبارت جریمه همبستگی است، که طبق رابطه ذیل محاسبه می‌شود.

$$P_i = -(O_i - \bar{O})^2 \quad (4)$$

که \bar{O} میانگین خروجی شبکه‌های عصبی پایه است.

طرح کلی روش یادگیری همبستگی منفی بر اساس تابع خطای مذکور در (شکل ۱) نمایش داده شده است.



(شکل ۱): طرح کلی روش یادگیری همبستگی منفی. در مرحله یادگیری این روش، همان‌طور که در شکل نمایش داده شده است، شبکه‌های پایه با استفاده از تابع خطای ویژه یادگیری همبستگی منفی به‌طور هم‌زمان مورد آموزش قرار می‌گیرند.

عبارت P_i را می‌توان به‌عنوان یک عبارت منظم‌سازی^۱ تعبیر کرد که در تابع خطای هر شبکه ترکیب لحاظ شده است. به‌کارگیری این قبیل عبارت‌های منظم‌سازی راه حل مرسوم برای ایجاد تعادل بهینه در توازن بایاس-واریانس-کوواریانس^۲ محسوب می‌شود. این عبارت برای محاسبه مقدار همبستگی خروجی‌ها به‌کار گرفته شده که در فرآیند همگرایی، کمینه شده و منجر به شبکه‌هایی با همبستگی منفی شود. ضریب λ پارامتری برای تنظیم میزان تأثیر عبارت همبستگی در مقابل تابع ریسک تجربی است که با تغییر آن می‌توان به تعادل بهینه بین تابع خطای هدف و عبارت جریمه همبستگی نزدیک شد. در هنگامی که این ضریب صفر لحاظ شود، عبارت همبستگی حذف شده و شبکه‌های سیستم ترکیبی به صورت مستقل از یکدیگر آموزش می‌بینند. میزان ارتباط و همبستگی میان شبکه‌های پایه با مقدار ضریب λ به‌صورت صریح قابل کنترل است. این تابع جریمه، شبکه‌های پایه سیستم ترکیبی را تشویق می‌کند تا هر یک قسمت‌ها یا جنبه‌های مختلفی از مسأله را یاد گرفته و مدل کنند؛ تا در همکاری آنها با یکدیگر، سیستم ترکیبی بتواند کل فضای مسأله را به‌خوبی پوشش دهد (Liu and Yao, 1999b).

¹ Regularization Term

² Bias-Variance-Covariance Tradeoff

به‌نحوی که وزن‌های ترکیب، تابعی از میزان خبرگی هر خبره به‌ازای هر ورودی خاص باشد.

همان‌طور که در قبل ذکر شد، سیستم‌های ترکیب از دو جزء اصلی تشکیل شده‌اند. در جزء اول، یعنی آموزش شبکه‌های عصبی پایه، بر طبق برتری خواص ذکر شده در فصل قبل (دارا بودن امکانی برای تنظیم پارامتر منظم‌سازی)، یادگیری همبستگی منفی به‌نحو کاراتری از اختلاط خبره‌های پایه رفتار می‌کند. برتری یادگیری همبستگی منفی از آنجا ناشی می‌شود که عبارت منظم‌سازی به‌کار گرفته شده در این روش موجب رسیدن این سیستم ترکیبی به تعادل بهینه در توازن بایاس-کوواریانس-کوواریانس و در نتیجه قابلیت تعمیم بهتر می‌شود؛ در حالی که اختلاط خبره‌های پایه فاقد این عبارت منظم‌سازی است (Liu and Yao, 1999a). از طرف دیگر، اختلاط خبره‌های پایه از نظر جزء دوم ترکیب، دارای روشی کاراتر برای ترکیب خروجی خبره‌ها می‌باشد (Kuncheva, 2004).

همان‌طور که از بررسی ویژگی‌های دو روش اختلاط خبره‌های پایه و یادگیری همبستگی منفی و بررسی نقاط ضعف و قوت هر یک در مقایسه با یکدیگر مشخص شد، این دو، ویژگی‌های مکملی دارند. بر مبنای این ایده به‌نظر می‌رسد که اگر بتوانیم سیستم مجتمعی طراحی کنیم که شامل ویژگی‌های مثبت هر دو روش باشد، این سیستم کارایی بهتری نسبت به اجزای تشکیل دهنده خود داشته باشد. در بخش بعدی، بر مبنای ایده‌ی تجمیع ویژگی، روش ترکیبی بهبود داده شده‌ی ارائه شده است که سعی در ترکیب ویژگی‌های مثبت روش‌های پایه‌ی اختلاط خبره‌ها و یادگیری همبستگی منفی دارد.

۳-۲- افزودن یادگیری همبستگی منفی به روش اختلاط خبره‌ها

روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی از توابع خطای مختلفی برای یادگیری و ایجاد همبستگی منفی میان شبکه‌های پایه استفاده می‌کنند. اگرچه روش اختلاط خبره‌های پایه نیز خبره‌هایی با همبستگی منفی تولید می‌کند، اما مانند روش یادگیری همبستگی منفی دارای پارامتر کنترلی برای تنظیم صریح و بهینه توازن بایاس-کوواریانس-کوواریانس نیست. برای این که این امکان یادگیری همبستگی منفی را به روش اختلاط خبره‌های پایه بیفزاییم، پارامتر کنترلی یادگیری همبستگی

بررسی و نقاط ضعف و قوت آنها در مقایسه با یکدیگر بررسی می‌شود. بر اساس ساختار و راهبرد یادگیری مشابهی که در هر دو روش اختلاط خبره‌های پایه و یادگیری همبستگی منفی وجود دارد و بر مبنای ویژگی‌های مکمل آن‌ها، ایده ترکیب ویژگی‌های این دو روش در قالب یک سیستم ترکیب مجتمع ممکن است بتواند با حفظ نقاط قوت روش‌های پایه و حذف نقاط ضعف‌شان کارایی را افزایش دهد. بر مبنای این ایده، در این بخش، روش ترکیبی جدید اضافه‌کردن یادگیری همبستگی منفی به الگوریتم همگرایی روش اختلاط خبره‌های پایه برای جمع‌کردن ویژگی‌های روش اختلاط خبره‌های پایه و یادگیری همبستگی منفی پیشنهاد شده است:

۳-۱- مقایسه نقاط ضعف و قوت

در این بخش با بررسی ویژگی‌های روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی، به مقایسه نقاط ضعف و قوت آن‌ها در مقایسه با یکدیگر خواهیم پرداخت. در ابتدا، ویژگی‌های مشترک این دو روش بررسی خواهد شد. هر دو روش ترکیب، شبکه‌های عصبی پایه را به صورت هم‌زمان و در فرآیندی با ارتباط و همکاری چندجانبه میان خبره‌ها آموزش می‌دهند. همان‌طور که در قبل هم ذکر شد، توابع متفاوت و ویژه این دو روش، ویژگی‌هایی دارند که موجب می‌شود خبره‌ها در فرآیندی رقابتی توأم با همکاری، زیرفضاها یا جنبه‌های مختلفی از فضای مسأله را آموزش دیده، به‌نحوی که سیستم ترکیبی در مجموع بتواند کل فضای مسأله را مدل‌سازی کند. به عبارت دیگر، توابع خطای این دو روش ویژگی‌هایی دارند که موجب می‌شود با تقسیم فضای ضمنی مسأله بین خبره‌ها، شبکه‌های عصبی پایه‌ای تولید کنند که علاوه بر بایاس بودن، دارای همبستگی منفی نیز باشند (Islam et al., 2008a).

در کنار این شباهت‌ها، این دو روش تفاوت‌هایی نیز با هم دارند. یکی از برتری‌های اختلاط خبره‌های پایه بر روش‌های ترکیبی مشابه دیگر، روش منحصر به فرد آن در ترکیب خروجی خبره‌هاست. اختلاط خبره‌های پایه از روشی مبتنی بر یادگیری برای ترکیب خروجی خبره‌ها استفاده می‌کند، که این قابلیت را دارد تا با مدل‌سازی میزان خبرگی شبکه‌های پایه در زیرفضاهای مختلف مسأله، به‌صورت پویا و بر حسب ورودی، خروجی خبره‌ها را به‌صورت وزن‌دار ترکیب کند. شبکه‌ی میانجی در مدل اختلاط خبره‌های پایه، خروجی خبره‌ها را طبق میانگین وزن‌دار ترکیب می‌کند،

شبکه میانجی در روش بهبود یافته به طور تقریبی مشابه روش قبلی عمل می کند؛ با این تفاوت که تابع خطای شبکه میانجی، با توجه به بهبود تابع خطای کل سیستم ترکیب، طبق رابطه زیر محاسبه می شود:

$$E_{G,MNCE} = \frac{1}{2}(h_{MNCE} - O_g)^2 \quad (12)$$

همان طور که در رابطه مشاهده می شود، پارامتر h آن با روابط قبلی شبکه میانجی متفاوت است؛ زیرا با اصلاح تابع خطای سیستم ترکیب، پارامتر h نیز تغییر کرده است. بدین ترتیب قوانین یادگیری شبکه میانجی نیز مشابه قبل طبق روابط ذیل محاسبه می شود:

$$\Delta w_{yg} = \eta_g (h_{MNCE} - O_g)(O_g(1 - O_g))O_{hg}^T \quad (13)$$

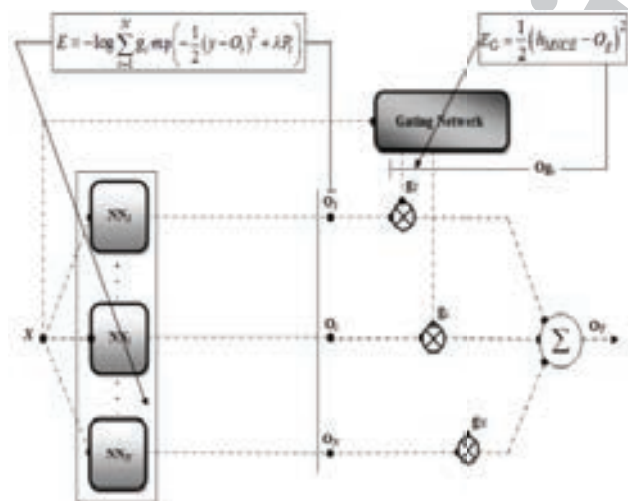
$$\Delta w_{hg} = \eta_g w_{yg}^T (h_{MNCE} - O_g) \quad (14)$$

$$(O_g(1 - O_g))O_{hg}(1 - O_{hg})x_i$$

خروجی نهایی سیستم نیز مشابه اختلاط خبرهها به صورت میانگین وزن دار طبق رابطه ذیل محاسبه می شود:

$$O_T = \sum_{j=1}^N O_j g_j \quad (15)$$

ساختار روش اختلاط خبرههایی با همگرایی منفی و الگوریتم یادگیری همزمان خبرهها و شبکه میانجی در (شکل ۲) نمایش داده شده است.



(شکل ۲): شمای کلی الگوریتم یادگیری اختلاط خبرههایی با همبستگی منفی. شمای کلی نحوه یادگیری همزمان شبکههای خبره و شبکه میانجی با استفاده از توابع خطای اصلاح شده در شکل نمایش داده شده است. شبکههای خبره در یک فرآیند رقابتی با همکاری شبکه میانجی به تقسیم فضا و مدل سازی حل مسأله می پردازند. پارامتر کنترلی اضافه شده λP_j این امکان را فراهم می کند تا میزان همبستگی منفی میان شبکههای خبره به صورت شبه بهینه تنظیم شود.

منفی را به تابع خطای اختلاط خبرههای پایه اضافه کرده ایم. پارامتر کنترلی P_j که به عنوان عبارت منظم سازی به تابع خطای اختلاط خبرههای پایه افزوده شده و تابع خطای اصلاح شده مدل اختلاط خبرهها در روابط ذیل آورده شده است.

$$E = -\log \sum_{j=1}^N g_j \left(-\frac{1}{2}(y - O_j)^2 + \lambda P_j \right) \quad (6)$$

$$P_j = -(O_j - \bar{O})^2 \quad (7)$$

عبارت کنترلی اضافه شده، همانند روش یادگیری همبستگی منفی، این امکان را فراهم می کند تا تعادل شبه بهینه در توازن بایاس-سواریانس-کوواریانس ایجاد و در نتیجه قابلیت تعمیم روش اختلاط خبرههای پایه بهبود پیدا کند. به دلیل این ویژگی، روش بهبود یافته اختلاط خبرههای ارائه شده را به نام روش اختلاط خبرههای با همبستگی منفی^۱ نام گذاری کرده ایم.

در ساختار روش اختلاط خبرههای با همبستگی منفی، هر خبره یک شبکه پرسپترون چندلایه با یک لایه مخفی در نظر گرفته شده است. با لحاظ کردن تابع خطای جدید، قوانین اصلاح وزن خبرهها در فرآیند همگرایی با استفاده از الگوریتم پس انتشار خطا^۲ در روابط ذیل آمده است:

$$h_{MNCE,i} = - \frac{g_i \exp\left(-\frac{1}{2}(y - O_i)^2 + \lambda P_i\right)}{\sum_{j=1}^N g_j \exp\left(-\frac{1}{2}(y - O_j)^2 + \lambda P_j\right)} \quad (8)$$

$$\Delta w_{h,i} = \eta_e h_{MNCE,i} w_y^T \left[(y - O_i) - \lambda \frac{\partial P_i}{\partial O_i} \right] (O_i(1 - O_i))O_{hi}(1 - O_{hi})x_i \quad (9)$$

$$\Delta w_{y,i} = \eta_e h_{MNCE,i} \left[(y - O_i) - \lambda \frac{\partial P_i}{\partial O_i} \right] (O_i(1 - O_i))O_{hi}^T \quad (10)$$

$$\frac{\partial P_i}{\partial O_i} = -2 \left(1 - \frac{1}{N} \right) (O_i - \bar{O}) \quad (11)$$

که η_e نرخ یادگیری، λ ضریب پارامتر کنترلی، g_i ، آئین خروجی شبکه میانجی بعد از اعمال عملگر بیشینه نرم، w_y و w_h به ترتیب وزنهای لایه پنهان و لایه خروجی شبکههای خبره است. O_h^T ترانزاده بردار O_h ، خروجی لایه مخفی شبکههای پایه است.

¹ Mixture of Negatively Correlated Experts

² Back-Propagation

در آزمایش‌های قبلی، روش‌های مورد بررسی در حل مسائل طبقه‌بندی مورد آزمون و مقایسه قرار می‌گرفتند؛ در حالی که در آزمایش سوم فرآیند همگرایی و یادگیری روش اختلاط خبره‌هایی با همگرایی منفی و اختلاط خبره‌های پایه را در مسئله رگرسیون و پیش‌بینی مورد بررسی قرار داده‌ایم. در این آزمایش، فرآیند یادگیری اختلاط خبره‌های پایه و اختلاط خبره‌هایی با همگرایی منفی از نقطه نظر نحوه توازن عبارت‌های بایاس-کوواریانس-کوواریانس بررسی شده است. آزمایش آخر بدین منظور طراحی شده است تا علت برتری اختلاط خبره‌هایی با همگرایی منفی بر اختلاط خبره‌های پایه را از لحاظ معیارهای یادگیری ماشین بررسی کند.

۴-۱- پارامترهای آزمون

در تمام آزمایش‌ها به جز آزمایش دوم، همه سیستم‌های ترکیبی از پنج شبکه پرسپترون چندلایه با یک لایه مخفی تشکیل شده‌اند. در آزمایش دوم، برای بررسی نحوه تأثیر اندازه سیستم ترکیبی بر کارایی روش‌های مورد مقایسه، سیستم‌های ترکیبی با اندازه‌های متنوعی شامل سه، پنج و هفت شبکه پایه آزموده شده‌اند. تعداد نورون‌ها در لایه مخفی برای تمام آزمایش‌ها، پنج نورون در نظر گرفته و الگوریتم یادگیری همه روش‌های ترکیبی بر اساس روش پس‌انتشار خطا کار می‌کند. در روش‌های اختلاط خبره‌های پایه، اختلاط خبره‌هایی با همگرایی منفی و ترکیب شبکه‌های روش یادگیری همبستگی منفی با شبکه میانجی، خبره‌ها و شبکه میانجی به ترتیب با مقادیر نرخ یادگیری $\eta_e=0.1$ و $\eta_g=0.05$ مورد آموزش قرار می‌گیرند. نرخ یادگیری شبکه‌های پایه روش یادگیری همبستگی منفی نیز مقدار 0.1 در نظر گرفته شده است. برای روش‌های یادگیری همبستگی منفی و اختلاط خبره‌هایی با همگرایی منفی، λ^* به عنوان مقدار بهینه λ ، برای کم‌ترین نرخ خطا در یک فرآیند آزمون و خطا با آزمودن مقادیر مختلف بازه $[0.001:0.2]$ (از صفر تا دو با گام‌های یک دهم) به‌ازای مجموعه اعتبارسنجی^۶ محاسبه و میزان کارایی با استفاده از تکنیک ارزیابی ضرب‌دری K بخشی، با $K=5$ اندازه‌گیری شده است، به نحوی که مجموعه داده به پنج بخش به‌طور تقریبی مساوی تقسیم و هر یک از این زیرمجموعه‌ها یک بار به عنوان مجموعه آزمون^۷ انتخاب می‌شود. به این ترتیب

⁶ Validation Set

⁷ Test Set

بر پایه الگوریتم یادگیری روش اختلاط خبره‌های با همبستگی منفی، خبره‌های سیستم ترکیبی در یک فرآیند یادگیری رقابتی به تقسیم فضای مسأله و مدل‌سازی آن می‌پردازند. شبکه میانجی با مدل‌سازی میزان خبرگی محلی شبکه‌های خبره، با تنظیم ضریب یادگیری آنها، این فرآیند تقسیم فضای میان خبره‌ها را مدیریت می‌کند. این فرآیند یادگیری رقابتی منجر به محلی‌سازی خبره‌ها در زیرفضاهای خود، که به احتمال هم‌پوشانی نیز دارند، می‌شود. همچنین لحاظ کردن پارامتر کنترلی همبستگی منفی در تابع خطا به سیستم کمک می‌کند تا مقدار همبستگی منفی میان خبره‌ها را به نحو مطلوب تنظیم کند. همچنین لحاظ کردن پارامتر کنترل همبستگی منفی در تابع خطا نیز به سیستم کمک می‌کند تا مقدار همبستگی منفی میان خبره‌ها را به نحو مطلوب تنظیم کند. همان‌طور که قبلاً توضیح داده شد، تنظیم مناسب میزان همبستگی میان خبره‌ها منجر به ایجاد تعادل شبه‌بهینه در توازن بایاس-کوواریانس-کوواریانس شده که این امر قابلیت تعمیم سیستم ترکیبی به ازای داده‌های آزمون را افزایش می‌دهد.

۴-۲- نتایج آزمایش‌ها

در این بخش، آزمایش‌هایی برای بررسی کارایی روش ارائه شده، انجام شده است. در آزمایش اول، وابستگی کارایی روش اختلاط خبره‌هایی با همگرایی منفی به پارامتر کنترلی λP_i بررسی شده است. آزمایش دوم برای مقایسه کارایی روش اختلاط خبره‌هایی با همگرایی منفی در مقابل روش‌های ترکیب پایه اختلاط خبره‌ها و یادگیری همبستگی منفی انجام شده است. برای اندازه‌گیری کارایی روش‌ها، چندین مسأله واقعی طبقه‌بندی از مجموعه داده‌های آزمون UCI به کار گرفته شده است. ویژگی‌های مجموعه داده‌های آزمون طبقه‌بندی مورد استفاده در (جدول ۱) به‌طور خلاصه ذکر شده است.

جدول ۱: اطلاعات اصلی مجموعه داده‌های آزمون معیار طبقه‌بندی

مجموعه داده	تعداد نمونه	بعد بردار ویژگی	تعداد دسته
آواها ^۱	۵۴۰۴	۵	۲
تصاویر ماهواره‌ای ^۲	۶۴۳۵	۴	۶
ارقام دست‌نویس ^۳	۱۰۹۹۲	۱۶	۱۰
شیشه ^۴	۲۱۴	۱۰	۶
وسایل نقلیه ^۵	۹۴۶	۱۸	۴

¹ Phoneme

² Satellite Images

³ Pen Digit

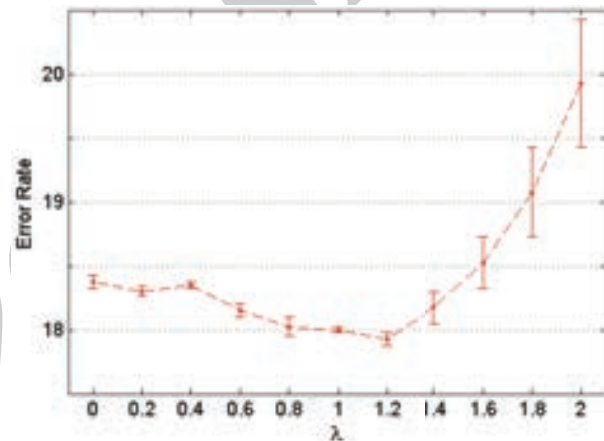
⁴ Glass

⁵ Vehicle


محاسبه کارایی بر اساس میانگین این پنج بار اجرا، گزارش می‌شود. بر پایه این تنظیمات و ملاحظات آزمایش‌های ذیل انجام شده است:

۴-۲- تأثیر پارامتر λ بر کارایی روش اختلاط خبره‌هایی با همبستگی منفی

در این آزمایش کارایی روش اختلاط خبره‌هایی با همبستگی منفی با ساختار پنج شبکه پایه به ازای مقادیر مختلف پارامتر کنترلی λ در طبقه‌بندی مجموعه داده‌های وسائل نقلیه و تشخیص ارقام دست‌نوشته مورد آزمون قرار گرفته است. تأثیر تغییر پارامتر کنترلی λ در بازه $[0:0.2:2]$ (از صفر تا دو با گام‌های دو دهم) بر روند تغییر نرخ خطای روش اختلاط خبره‌هایی با همبستگی منفی در (شکل ۳) نمایش داده شده است.



a(۳)



b(۳)

(شکل ۳): نمودارهای وابستگی نرخ خطای روش اختلاط خبره‌هایی با همبستگی منفی به پارامتر کنترلی λ به ترتیب در مسائل طبقه‌بندی مجموعه داده‌های تشخیص ارقام دست‌نوشته و وسائل نقلیه به ترتیب در نمودارهای a, b نشان داده شده است.


همان‌طور که در قبل اشاره شد، ضریب λ به روش اجازه می‌دهد تا با کنترل میزان تأثیر عبارت همبستگی، تعادلی شبه‌بهینه را در توازن عبارت‌های دقت و گوناگونی ایجاد کند. هر دو نمودار نشان می‌دهد که در ابتدا نرخ خطای روش اختلاط خبره‌هایی با همبستگی منفی با افزایش مقدار λ کاهش پیدا کرده و سپس افزایش پیدا می‌کند. این چنین روند تغییر خطایی در این نمودارها نیز مسأله توازن مذکور را نشان می‌دهد. همان‌طور که در نمودارها مشخص است، روش ما در مورد مسأله‌های طبقه‌بندی وسائل نقلیه و تشخیص ارقام دست‌نویس به ترتیب در مقادیر $\lambda=0.8$ و $\lambda=1.2$ به حداقل نرخ خطای طبقه‌بندی رسیده است. هم‌چنین همان‌طور که در تصویر مشاهده می‌شود، با افزایش مقادیر λ ، نرخ خطا به صورت چشم‌گیری افزایش پیدا می‌کند. این مسأله به این دلیل رخ داده است که در مقادیر بزرگ λ ، روش به جای تمرکز بر کاهش نرخ خطای طبقه‌بندی پایه، بیش‌تر عبارت همبستگی را کمینه می‌نماید.

۴-۳- روش اختلاط خبره‌هایی با همبستگی


منفی در مقایسه با روش‌های پایه

در این آزمایش، روش اختلاط خبره‌هایی با همبستگی منفی با روش‌های پایه سازنده خود از جمله اختلاط خبره‌های پایه و یادگیری همبستگی منفی به ازای سیستم‌های ترکیبی با پنج شبکه خبره پایه در پنج مسأله آزمون طبقه‌بندی مورد بررسی و مقایسه قرار گرفته است. برای تنظیم بهینه پارامتر λ در روش‌های یادگیری همبستگی منفی و اختلاط خبره‌هایی با همگرایی منفی، مقادیر مختلف λ در بازه $[0:0.1:2]$ روی مجموعه ارزیابی مورد آزمون قرار گرفته و مقدار بهینه انتخاب شده است. با این شرایط، نرخ خطای روش‌های ترکیبی مورد مقایسه در جدول ۲ گزارش شده است.


در این بررسی، روش آزمون آماری t-test بر اساس نرخ‌های خطای به دست آمده در جدول بالا مورد استفاده قرار گرفته تا تعیین کند آیا نرخ خطای به دست آمده توسط روش اختلاط خبره‌هایی با همگرایی منفی در مقایسه با روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی از لحاظ آماری به طور قابل توجهی کاهش پیدا کرده است یا خیر. بر اساس این آزمون آماری با لحاظ کردن 95% اطمینان‌پذیری، روش اختلاط خبره‌هایی با همگرایی منفی در تمام مسائل طبقه‌بندی مورد آزمایش، به جز مسأله آواها، خطا را به طور قابل ملاحظه‌ای نسبت به روش اختلاط خبره‌های پایه افزایش داده است. در مسأله طبقه‌بندی آواها،




a (۴)




b (۴)



c (۴)



d (۴)



e (۴)

(شکل ۴): نمودارهای نرخ خطای اختلاط خبره‌هایی با همگرایی منفی در مقایسه با روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی، در اندازه‌های مختلف سیستم ترکیبی در پنج مسأله مشمول، به ترتیب مسأله‌های طبقه‌بندی آواها، تصاویر ماهواره‌ای، ارقام دست‌نویس، شیشه و وسائل نقلیه در تصاویر d-a نمایش داده شده است.

اگر چه روش ارائه شده در مقایسه با اختلاط خبره‌های پایه خطای کمتری داشته است، اما میزان این کاهش قابل ملاحظه نیست.

(جدول ۲): مقایسه نرخ خطای روش ارائه شده، اختلاط خبره‌هایی با همبستگی منفی، در مقایسه با روش‌های پایه سازنده خود شامل اختلاط خبره‌های پایه و یادگیری همبستگی منفی.

مجموعه داده	نرخ خطا (%)				
	اختلاط خبره‌های پایه		یادگیری همبستگی منفی		
میانگین (واریانس)	λ^*	میانگین (واریانس)	λ^*	میانگین (واریانس)	
آواها	17.9 (9E-2)	0.8	18.3 (5E-2)	1	17.1 (2E-1)
تصاویر ماهواره‌ای	16.2 (1E-1)	1	15.9 (7E-2)	1.1	13.8 (3E-1)
ارقام دست‌نویس	6.4 (2E-1)	1	5.5 (8E-2)	0.8	4.9 (3E-1)
شیشه	30.8 (3E-1)	1	31.4 (1E-1)	0.1	28.3 (4E-1)
وسائل نقلیه	19.5 (1E-1)	0.8	18.6 (6E-2)	1.2	17.7 (2E-1)

بر اساس این آزمون آماری با لحاظ کردن ۹۵٪ اطمینان‌پذیری، روش اختلاط خبره‌هایی با همگرایی منفی در مقایسه با روش یادگیری همبستگی منفی کارایی را به‌طور قابل ملاحظه‌ای در همه مسائل مورد آزمون به‌جز مسائل آواها و تشخیص ارقام دست‌نویس افزایش داده است. در این دو مسأله نیز اگرچه خطای طبقه‌بندی کاهش پیدا کرده، اما این کاهش از لحاظ این آزمون آماری قابل توجه نبوده است.

در قسمت دوم این آزمایش، برای بررسی نحوه عملکرد این روش‌ها به‌ازای اندازه‌های مختلف سیستم‌های ترکیبی مورد مقایسه، به‌ازای سه حالت مختلف شامل ۳، ۵ و ۷ خبره پایه در پنج مسأله آزمون طبقه‌بندی مورد آزمون قرار گرفته‌اند. با لحاظ کردن تأثیر اندازه سیستم ترکیبی بر مبنای تعداد خبره‌های پایه در مقایسه کارایی روش‌ها، می‌توانیم مقایسه منطقی‌تری انجام دهیم. نرخ خطای روش اختلاط خبره‌هایی با همگرایی منفی در مقایسه با روش‌های اختلاط خبره‌هایی با همگرایی منفی و یادگیری همبستگی منفی در اندازه‌های مختلف سیستم ترکیبی در پنج مسأله طبقه‌بندی در نمودارهای ذیل نمایش داده شده است:

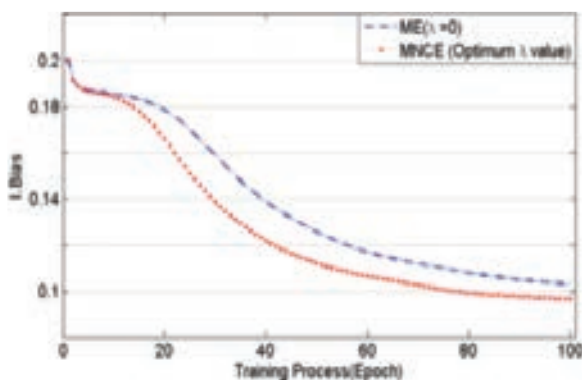
مقدار تخمینی میانگین مربع خطا نیز که جمع سه عبارت بالایی است، طبق رابطه ذیل محاسبه می‌شود:

$$IMSE = \frac{1}{|X|} \sum_{i=1}^{|X|} \frac{1}{N} \sum_{n=1}^N (O_{ens}(x_i, n) - y_i)^2 \quad (21)$$

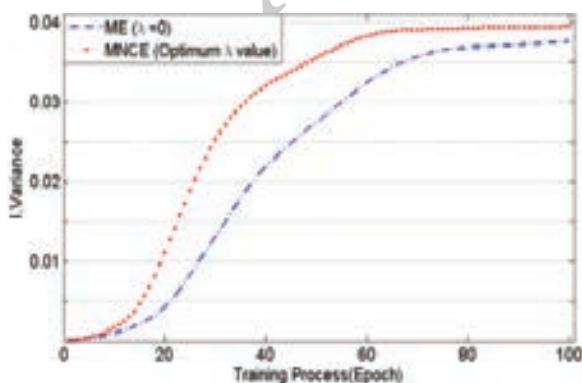
ما روند تغییر عبارت‌های مختلف تشکیل دهنده خطای تعمیم در فرآیند یادگیری روش‌های اختلاط خبره‌های با همگرایی منفی و اختلاط خبره‌های پایه را در یک مسأله رگرسیون بررسی کرده‌ایم. تابع مورد آزمون رگرسیون در این مسأله عبارتند از:

$$f(x) = \frac{1}{13} \left[10 \sin(\pi x_1 x_2) + 20 \left(x_3 - \frac{1}{2} \right)^2 + 10x_4 + 5x_5 \right] - 1 \quad (22)$$

که $x = [x_1 \ x_2 \ x_3 \ x_4 \ x_5]$ که مقادیر هر بعد در بازه $[0, 1]$ و مقدار خروجی تابع نیز در بازه $[0, 1]$ تغییر می‌کند. شرایط و تنظیمات آزمایش مشابه پیشنهاد جیکابز (Jacobs, 1997) لحاظ شده است. روند تغییرات عبارت‌های تخمینی بایانس، واریانس، کوواریانس و میانگین مربع خطا در طی روند یادگیری روش‌های اختلاط خبره‌های با همگرایی منفی و اختلاط خبره‌های پایه در نمودارهای (a-5) و (d) به ترتیب نمایش داده شده است.



a (5)



d (5)

همان‌طور که در نمودارهای بالا مشاهده می‌شود، روش اختلاط خبره‌هایی با همگرایی منفی در مقایسه با روش‌های اختلاط خبره‌های پایه و یادگیری همبستگی منفی در تمام مسائل مورد آزمون و به‌ازای همه اندازه‌های مختلف سیستم‌های ترکیبی نرخ خطای به مراتب کمتری داشته است.

۴-۴- بررسی اجزای خطای تعمیم در فرآیند یادگیری روش ارائه شده

جیکابز در مقاله (Jacobs, 1997) سیستم ترکیبی‌ای را بررسی کرده است که در آن خروجی کلی بر اساس میانگین وزن‌دار خبره‌های پایه محاسبه می‌شود و در چنین سیستمی، تخمین‌هایی برای اندازه‌گیری مقدار بایانس، واریانس و کوواریانس که سه جزء تشکیل دهنده مربع خطای تعمیم هستند، ارائه شده است. برای ارائه این تخمین‌ها، ابتدا روابط پایه‌ای معرفی می‌شوند.

تخمین میانگین خروجی سیستم ترکیبی به‌ازای ورودی x_i از مجموعه داده آزمون، طبق فرمول ذیل محاسبه می‌شود:

$$\overline{O_{ens}(x_i)} = \sum_{n=1}^N O_{ens}(x_i, n) \quad (16)$$

که $O_{ens}(x_i, n)$ خروجی سیستم ترکیبی به‌ازای ورودی x_i در اجرای n ام و N تعداد کل مراحل اجراست. تخمین میانگین وزن‌دار خروجی خبره k ام به‌ازای ورودی x_i طبق فرمول ذیل محاسبه می‌شود:

$$\overline{g_k(x_i) O_k(x_i)} = \frac{1}{N} \sum_{n=1}^N g_k(x_i, n) O_k(x_i, n) \quad (17)$$

که $g_k(x_i, n)$ خروجی k ام شبکه میانجی در اجرای n ام و $O_k(x_i, n)$ خروجی خبره k ام در اجرای n ام است.

بر این اساس، مقادیر تخمینی بایانس، واریانس و کوواریانس طبق روابط ذیل محاسبه می‌شوند:

$$IB = \frac{1}{|X|} \sum_{i=1}^{|X|} (\overline{O_{ens}(x_i)} - y_i)^2 \quad (18)$$

$$IV = \sum_k \frac{1}{|X|} \sum_{i=1}^{|X|} \frac{1}{N} \sum_{n=1}^N (g_k(x_i, n) O_k(x_i, n) - \overline{g_k(x_i) O_k(x_i)})^2 \quad (19)$$

$$IC = \sum_k \sum_{m \neq k} \frac{1}{|X|} \sum_{i=1}^{|X|} \frac{1}{N} \sum_{n=1}^N (g_k(x_i, n) O_k(x_i, n) - \overline{g_k(x_i) O_k(x_i)}) \cdot (g_m(x_i, n) O_m(x_i, n) - \overline{g_m(x_i) O_m(x_i)}) \quad (20)$$


که y_i برچسب متناظر ورودی x_i و $|X|$ اندازه مجموعه آزمون است.

اشاره کرده و نیز در تصاویر b و c مشخص است، در طی فرآیند محلی‌سازی خبره‌ها مقدار واریانس تخمینی خروجی-های وزن‌دار خبره‌ها افزایش و مقدار کوواریانس تخمینی خروجی‌های وزن‌دار خبره‌ها کاهش پیدا کرده است.

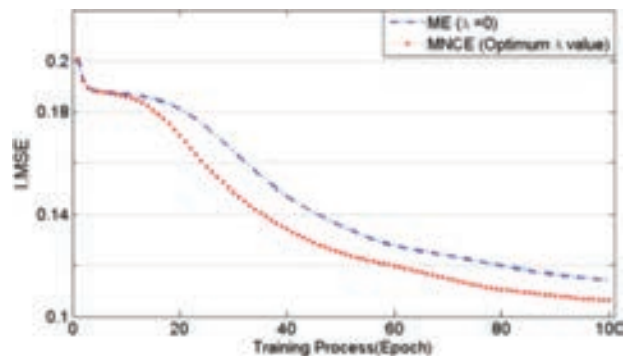
همان‌طور که در نمودار بالا مشخص است، پارامتر منظم‌سازی اضافه شده به تابع خطای روش ارائه شده، علاوه بر کنترل عبارت‌های واریانس و کوواریانس، مقدار عبارت بایاس را نیز در مقایسه با روش اختلاط خبره‌ها کاهش داده است. همان‌طور که در نمودار c مشخص است، بر اثر عبارت اضافه شده کنترل همبستگی منفی در تابع خطای روش اختلاط خبره‌های با همگرایی منفی، عبارت کوواریانس روش ما در مقایسه با روش اختلاط خبره‌ها کاهش پیدا کرده است؛ بنابراین، می‌توان گفت که روش اختلاط خبره‌های با همگرایی منفی با اعمال همبستگی منفی بیشتر میان خبره‌های پایه، به‌رغم افزایش واریانس موجب کاهش دو عبارت بایاس و کوواریانس خطا شده که در مجموع کاهش میانگین مربع خطای تعمیم را نتیجه داده است.

۴-۴-۱- تأثیر پارامتر λ بر عبارت‌های خطای تعمیم در روش ارائه شده

هدف از این آزمایش بررسی وابستگی عبارت‌های بایانس، واریانس، کوواریانس و خطای تعمیم به پارامتر کنترلی λ در روش ارائه شده است. شرایط و تنظیمات آزمایش، مشابه آزمایش قبلی لحاظ شده است، با این تفاوت که مقادیر مورد بررسی، پس از اتمام فرآیند یادگیری ترکیب اندازه‌گیری شده است. نتایج حاصل از روش اختلاط خبره‌های با همگرایی منفی در حل مسأله رگرسیون مذکور در آزمایش قبل به‌زای مقادیر مختلف λ در بازه [0:0.1:2] در نمودارهای ذیل نمایش داده شده است.




c (۵)




d (۵)

نمودار ۵ (a-d) روند تغییر عبارت‌های بایانس، واریانس، کوواریانس و میانگین مربع خطا در طی روند یادگیری روش‌های اختلاط خبره‌های با همگرایی منفی و اختلاط خبره‌های پایه که به ترتیب با رنگ‌های آبی و قرمز نشان داده شده است. همان‌طور که نتایج آزمایش در نمودارها نشان می‌دهد، مقدار عمده میانگین مربع خطا از بایاس ناشی می‌شود. به همین دلیل، همان‌طور که در نمودارها مشاهده می‌شود، روند تغییر میانگین مربع خطا بیش از همه، به روند تغییر عبارت بایاس شباهت دارد.


خبره‌های پایه در روش‌های اختلاط خبره‌های با همگرایی منفی و اختلاط خبره‌های پایه، طی فرآیند یادگیری در توزیع‌های مختلفی از فضای مسأله به‌صورت محلی خبره می‌شوند. همان‌طور که جیکابز (Jacobs, 1997)




a (۶)



b (۶)



c (۶)



d (۶)

(شکل ۶ a-d): وابستگی عبارات‌های بایانس، واریانس، کوواریانس و خطای تعمیم به پارامتر کنترلی λ در روش اختلاط خبره‌های با همگرایی منفی.

بایاس-واریانس-کوواریانس ایجاد و کارایی را افزایش دهد. روش ترکیبی اختلاط خبره‌هایی با همگرایی منفی، در چند مسألهٔ آزمون پیش‌بینی و طبقه‌بندی با روش‌های پایهٔ اختلاط خبره‌ها و یادگیری همبستگی منفی مورد مقایسه قرار گرفته است. نتایج آزمایش‌ها نشان داده است که روش پیشنهادی، با حفظ نقاط قوت و کاهش ضعف‌های روش‌های پایه، توانسته کارایی را به‌طور قابل ملاحظه‌ای نسبت به آنها افزایش دهند. همچنین در آزمایش پایانی با بررسی پارامترهای میانگین مربع خطا، شامل: بایاس، واریانس و کوواریانس، علت برتری اختلاط خبره‌هایی با همگرایی منفی بر اختلاط خبره‌های پایه را توجیه و نمایش داده‌ایم.

سپاس‌گزاری

این تحقیق در قالب طرح پژوهشی "افزایش نرخ کارایی طبقه‌بندی با استفاده از تجمیع ویژگی‌های مؤثر روش‌های مختلف ترکیب شبکه‌های عصبی" با حمایت دانشگاه آزاد اسلامی واحد کرج انجام پذیرفته شده است.

۶- منابع

Avnimelech R, Intrator N (1999) Boosted mixture of experts: an ensemble learning scheme. *Neural computation* 11 (2):483-497.

Brown G, Wyatt JM (2003) Negative correlation learning and the ambiguity family of ensemble methods. *Multiple Classifier Systems, Proceeding* 2709:266-275.

Ebrahimpour R, Nikoo H, Masoudnia S, Yousefi MR, Ghaemi MS (2011) Mixture of MLP-experts for trend forecasting of time series: A case study of the Tehran stock exchange. *International Journal of Forecasting* 27 (3):804-816. doi:10.1016/j.ijforecast.2010.02.015.

Ghaemi M, Masoudnia S, Ebrahimpour R (2010) A new framework for small sample size face recognition based on weighted multiple decision templates. *Neural Information Processing Theory and Algorithms* 6643/2010:470-477. doi:10.1007/978-3-642-17537-4_58.

Hansen JV (2000) Combining predictors: Meta machine learning methods and bias/variance & ambiguity decompositions. *Computer Science Dept., Aarhus Univ.*

Islam MM, Yao X, Nirjon SMS, Islam MA, Murase K (2008a) Bagging and boosting negatively correlated neural networks. *Ieee T Syst Man Cy B* 38 (3):771-784. doi:Doi 10.1109/Tsmcb.2008.922055.

نتایج نشان می‌دهد که به‌ازای تغییر λ در بازه $[0,2]$ ، ابتدا عبارت بایاس کاهش و سپس افزایش پیدا کرده است، به‌نحوی که کمینهٔ مقدار بایاس در $\lambda=1.6$ حاصل شده است. همان‌طور که نمودار a نشان می‌دهد، به‌ازای مقادیر بزرگ λ عبارت بایاس افزایش پیدا می‌کند. این پدیده به این دلیل است که در چنین شرایطی فرآیند یادگیری به‌جای کمینه‌کردن عبارت خطای ترکیب، بر روی کمینه‌کردن عبارت همبستگی خبره‌های پایه تمرکز می‌کند.

همان‌طور که ذکر شد، با افزایش پارامتر λ فرآیند یادگیری بر روی کاهش عبارت خطای همبستگی تمرکز می‌کند که به همین دلیل با افزایش λ مقدار واریانس افزایش و مقدار کوواریانس کاهش پیدا کرده است. کاهش عبارت کوواریانس به حدی است که منجر به وجود آمدن کوواریانس منفی میان خبره‌های پایه شده است.

مشابه آزمایش قبلی، نتایج نشان می‌دهد که عمده خطای تعمیم از عبارت بایاس ناشی می‌شود؛ به‌نحوی که روند تغییر خطای تعمیم، بیش از همه به روند تغییر بایاس شباهت دارد. نکتهٔ قابل توجه این است که روش ارائه شده، نه تنها میزان واریانس و کوواریانس سامانهٔ ترکیبی را کنترل می‌کند، بلکه مقدار بایاس آن را نیز به‌طور قابل توجهی کاهش داده است. بنابراین روش ارائه شده بر مبنای کنترل تمام عبارت‌های خطا به‌وسیلهٔ انتخاب مقدار بهینهٔ پارامتر λ موجب افزایش قابلیت تعمیم شده است. قابل ذکر است که در این سیستم ترکیبی ارائه شده، توازن بایاس-واریانس-کوواریانس به‌ازای مقدار $\lambda=1/6$ به مقدار بهینهٔ خود رسیده که کمینه‌شدن خطای تعمیم را نتیجه داده است.

۵- نتیجه‌گیری

در این مقاله، ویژگی‌های مختلف دو روش اختلاط خبره‌ها و یادگیری همبستگی منفی را مرور و نقاط قوت و ضعف آن‌ها را در مقایسه با یکدیگر بررسی کردیم. بررسی خصوصیات این دو روش در مقایسه با یکدیگر نشان داد که آن‌ها ویژگی‌های متفاوت و البته مکملی نسبت به هم دارند؛ به‌نحوی که اگر بتوان سیستمی ترکیبی شامل ویژگی‌های مثبت هر دو روش طراحی کرد، به‌احتمال کارایی بهتر از روش‌های پایهٔ خود داشته باشد. در این مقاله، ایده‌ای را برای ترکیب ویژگی‌های این دو روش پیشنهاد کرده‌ایم: ایدهٔ اختلاط خبره‌هایی با همگرایی منفی. در روش ارائه شده، قابلیت پارامتر کنترلی روش یادگیری همبستگی منفی به تابع خطای روش اختلاط خبره‌ها افزوده شده، که روش اختلاط خبره‌ها را قادر می‌سازد تعادل بهینه‌ای را در توازن



جواد محمدزاده کارشناسی و کارشناسی ارشد خود را در رشته علوم کامپیوتر به ترتیب از دانشگاه شهید باهنر کرمان در سال ۱۳۸۳ و دانشگاه تهران در سال ۱۳۸۶ دریافت کرده است. هم اکنون ایشان عضو هیأت علمی گروه کامپیوتر در دانشگاه آزاد واحد کرج هستند و در زمینه‌های علمی طراحی و بهینه‌سازی الگوریتم‌ها، محاسبات نرم، شبکه‌های عصبی، بیوانفورماتیک، طراحی ساختار دوم RNA و مدل‌سازی شبکه‌های تنظیم ژنی فعالیت می‌کنند.
نشانی رایانامک ایشان، عبارتست از:

j.mohammadzadeh@kiau.ac.ir



سعید مسعودنیا تحصیلات دوره کارشناسی و کارشناسی ارشد را در رشته علوم کامپیوتر در دانشگاه تهران به ترتیب در سال‌های ۱۳۸۷ و ۱۳۹۰ به پایان رسانده است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: یادگیری ماشین، پردازش الگو و بینایی ماشین و آنالیز سیگنال‌های مغزی است.
نشانی رایانامک ایشان، عبارتست از:

s.masoudnia@gmail.com



علی آراونی تحصیلات دوره کارشناسی و کارشناسی ارشد را در رشته مهندسی برق در دانشگاه تربیت دبیر شهید رجایی تهران به ترتیب در سال‌های ۱۳۸۸ و ۱۳۹۰ به پایان رسانده است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش الگو، شبکه‌های عصبی و علوم اعصاب شناختی است.
نشانی رایانامک ایشان، عبارتست از:

ali.araany@gmail.com

Islam MM, Yao X, Shahriar Nirjon S, Islam MA, Murase K (2008b) Bagging and boosting negatively correlated neural networks. Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on 38 (3):771-784.

Jacobs RA (1997) Bias/variance analyses of mixtures-of-experts architectures. Neural Comput 9 (2):369-383.

Jacobs RA, Jordan MI, Nowlan SJ, Hinton GE (1991) Adaptive mixtures of local experts. Neural computation 3 (1):79-87.

Kuncheva LI (2004) Combining pattern classifiers: methods and algorithms. Wiley-Interscience.

Liu Y, Yao X (1999a) Ensemble learning via negative correlation. Neural Networks 12 (10):1399-1404.

Liu Y, Yao X (1999b) Simultaneous training of negatively correlated neural networks in an ensemble. Ieee T Syst Man Cy B 29 (6):716-725.

Masoudnia S, Ebrahimpour R (2012) Mixture of Experts, a Literature Survey. Artif Intell Rev. doi:Accepted.

Masoudnia S, Rostami M, Tabassian M, Sajedin A, Ebrahimpour R Evidence-based mixture of MLP-experts. In: IEEE International Joint Conference of Neural Networks, 2010 2010. IEEE, pp 1-7.

Rokach L (2010a) Ensemble-based classifiers. Artificial Intelligence Review 33 (1):1-39.

Rokach L (2010b) Pattern classification using ensemble methods, vol 75. World Scientific Pub Co Inc,.

Ubeyli ED (2009) Modified mixture of experts employing eigenvector methods and Lyapunov exponents for analysis of electroencephalogram signals. Expert Syst 26 (4):339-354. doi:DOI 10.1111/j.1468-0394.2009.00490.x.

Ubeyli ED, Ilbay K, Ilbay G, Sahin D, Akansel G (2010) Differentiation of Two Subtypes of Adult Hydrocephalus by Mixture of Experts. J Med Syst 34 (3):281-290. doi:DOI 10.1007/s10916-008-9239-4.

Waterhouse SR (1997) Classification and regression using mixtures of experts. Unpublished doctoral dissertation, Cambridge University