

طبقه‌بندی مشکلات خودمراقبتی دانش آموزان ناتوان جسمی -

حرکتی با استفاده از شبکه‌های عصبی و الگوریتم ژنتیک

سید محمدمهدی فاطمی بوشهری^۱، محسن سرداری زارچی^۳

^۱ گروه مهندسی نرم افزار، پردیس علوم و تحقیقات یزد، دانشگاه آزاد اسلامی، یزد، ایران، ms.mfatemi@iauyazd.ac.ir

^۲ گروه مهندسی نرم افزار، واحد یزد، دانشگاه آزاد اسلامی، یزد، ایران، ms.mfatemi@iauyazd.ac.ir

^۳ گروه کامپیوتر، دانشکده فنی مهندسی، دانشگاه حائری میبد، sardari@haeri.ac.ir

چکیده

هدف این پژوهش ارائه و ارزیابی یک سیستم خبره مبتنی بر شبکه عصبی مصنوعی برای طبقه‌بندی مشکلات خود مراقبتی کودکان ناتوان جسمی - حرکتی است. وجود یک سیستم خبره با این قابلیت باعث کمک به نهادهای مرتبط با آموزش و پرورش استثنایی می‌شود. این مقاله مدلی به منظور طبقه‌بندی مشکلات خودمراقبتی کودکان ناتوان جسمی - حرکتی بر پایه چارچوب ICF-CY پیشنهاد می‌دهد. با توجه به وجود محدودیت در دسترسی به مجموعه داده استاندارد در رابطه با کودکان ناتوان جسمی - حرکتی، در این تحقیق ابتدا یک مجموعه داده از این کودکان طبق ICF-CY تدوین شده است. سپس با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم تکاملی ژنتیک، یک سیستم خبره طراحی و با مجموعه داده تدوین شده آموزش داده شد. در پایان سیستم ارائه شده مورد ارزیابی قرار گرفته است. در نهایت ما به این نتیجه رسیدیم که با استفاده از شبکه‌های عصبی و الگوریتم ژنتیک می‌توان سیستمی ارائه کرد تا علاوه بر کاهش ابعاد ویژگی‌ها و تعیین ویژگی‌های مؤثر در طبقه‌بندی مشکلات خودمراقبتی کودکان، توانایی طبقه‌بندی این مشکلات را با دقت بیش از ۹۳ درصد داشته باشد.

واژه‌های کلیدی

سیستم‌های خبره، شبکه عصبی مصنوعی، الگوریتم ژنتیک، طبقه‌بندی مشکلات دانش‌آموزان استثنایی

۱- مقدمه

و طبقه‌بندی صحیح مشکلاتی که افراد معلول با آن روبرو هستند امری ضروری است. در این راستا کمبود نیروی انسانی متخصص باعث افزایش فشار کاری و عدم تشخیص به موقع این مشکلات می‌شود. تاکنون استانداردهای زیادی برای طبقه‌بندی سطح انواع معلولیت‌ها ارائه شده‌اند که یکی از آن‌ها استاندارد ICF-CY است [۴]. ICF-CY یک استاندارد طبقه‌بندی چندمنظوره برای استفاده در زمینه‌های گوناگون است. یکی از موضوعات مطرح شده در این استاندارد موضوع خودمراقبتی است. طبق این استاندارد، خودمراقبتی به صورت فعالیت‌هایی نظیر شستشوی لباس، خشک کردن خود، لباس پوشیدن، خوردن و نوشیدن و مراقبت از سلامتی فرد تعریف شده است و برای آن سطوح مختلفی در نظر گرفته شده است [۴]. بدیهی است به علت تنوع سطوح مشکلات خودمراقبتی افراد معلول و همچنین کمبود نیروی متخصص در این زمینه، وجود یک سیستم خبره که بتواند در طبقه‌بندی مشکلات خودمراقبتی معلولین جسمی - حرکتی به کمک افراد خبره بیاورد ضروری به نظر می‌رسد.

طبق تعریف سازمان بهداشت جهانی، معلولیت به عنوان یک اصطلاح چتر برای آسیب‌ها، محدودیت‌های کارکردی و محدودیت‌های مشارکتی مطرح شده است. طبق این تعریف معلولیت نتیجه یک اختلال یا ناتوانی است که از انجام یک یا چند نقش طبیعی که مبتنی بر سن، جنسیت و سایر عوامل اجتماعی و فرهنگی است کاسته یا جلوگیری می‌کند [۱]. بررسی افراد ۱۵ سال به بالا مربوط به ۷۰ کشور جهان در سال ۲۰۱۰، نشان‌دهنده شیوع ۱۵/۶ تا ۱۹/۴ درصدی معلولیت در جهان است. شیوع معلولیت در ایران، حدود ۳ میلیون نفر برآورد شده است [۲]. طبق تعریف برون و ترنر معلولیت‌های جسمی - حرکتی، به آسیب‌هایی گفته می‌شود که یک یا بیش از یکی از فعالیت‌های فرد را محدود می‌کند. به عبارت دیگر معلولیت جسمی به حالتی اطلاق می‌شود که توانایی فرد را جهت استفاده از بدن خود محدود می‌سازد [۳] با توجه به اینکه معلولیت و پیامدهای جسمی، روانی و اجتماعی آن بر روی رشد و توسعه یک کشور تأثیر منفی می‌گذارد، شناخت

این مقاله مدلی را به منظور طبقه‌بندی مشکلات خودمراقبتی کودکان ناتوان جسمی - حرکتی ارائه می‌دهد. در قسمت دوم تفاوت‌های متدها و مدل‌های کامپیوتری استفاده‌شده جهت تشخیص و طبقه‌بندی انواع اختلال‌های کودکان استثنایی مورد بررسی قرار می‌گیرد. با بررسی دقیق تجربیات قبلی، یک روش مفید جهت فرایند طبقه‌بندی، تعیین می‌گردد. در قسمت سوم مشخصه‌های سیستم تعریف می‌شود. قسمت چهارم به معرفی سیستم پیشنهادی و بررسی نتایج آزمایش‌ها می‌پردازد. در نهایت و در قسمت پنجم نتیجه‌گیری و کارهای آینده ارائه خواهد شد.

۲- بررسی کارهای گذشته

۲-۱- تقسیم‌بندی تحقیقات انجام‌شده

مدل‌ها و متدهای تشخیص اختلال‌های کودکان استثنایی را می‌توان به چهار دسته کلی تقسیم کرد. این تقسیم‌بندی بر اساس مباحث تئوری و ویژگی‌های کامپیوتری متدها و مدل‌ها انجام‌شده است. مجموعه زیر بر اساس این مدل‌ها و متدها تدوین شده است.

- متدولوژی‌های پردازش سیگنال دیجیتال
- متدولوژی‌های پردازش تصویر دیجیتال (DIP)
- متدولوژی‌های کامپیوتری نرم‌افزاری (مانند شبکه‌های عصبی مصنوعی و سیستم‌های فازی)
- تکنیک‌های محاسباتی ترکیبی (تکنیک‌های پردازش تصویر و سیگنال به همراه تکنیک‌های نرم‌افزاری)

۲-۲- مروری بر کارهای گذشته

بیشترین فعالیت در زمینه هوشمند سازی فرایند تشخیص و طبقه‌بندی اختلال‌های کودکان استثنایی در زمینه اختلال یادگیری انجام شده است. با این وجود در ادامه بررسی کاملی در مورد مدل‌های ارائه‌شده برای سایر اختلال‌ها نیز بیان خواهد شد.

۲-۱-۲- تشخیص و طبقه‌بندی اختلال‌های یادگیری

Mico-Tormos و همکاران (۲۰۰۲) به این نتیجه رسیدند که تحلیل پاسخ حرکت‌های چشم یک کودک از طریق بررسی سیگنال‌های چشمی می‌تواند منجر به تشخیص اختلال یادگیری شود. از تحلیل‌های کامپیوتری این نکته به دست آمد که ارتباط بسیار زیادی بین فعالیت‌های عصبی و پاسخ‌های چشم وجود دارد، همچنین در تعداد زیادی از مطالعات، وابستگی خطی حرکت چشم بر سرعت محرک بیان و تأیید شده است [۵]. Novak و همکاران (۲۰۰۴) مجموعه‌ای از خصوصیات سیگنال‌های حرکت عمودی و افقی چشم را با استفاده از نگاشت خودسازمان‌دهی کننده و الگوریتم ژنتیک محاسبه کردند. آن‌ها به این نتیجه رسیدند که سرعت خواندن، با احتمال سالم بودن بیمار افزایش می‌یابد [۶]. Fonseca و همکاران (۲۰۰۶) با مطالعه امواج مغزی گوناگون به یک مغز نگاره (EEG) جهت تعیین اختلالات فعالیت‌های الکتریکی مغزی دست یافتند. آن‌ها به این نتیجه رسیدند که تفاوت زیادی در امواج مغزی یک کودک عادی با یک کودک

دارای اختلال یادگیری وجود دارد [۷]. Asseondi و همکاران (۲۰۰۶) به بررسی مقادیر توان وابسته و مطلق مغز نگاره در هنگام بیداری و خواب پرداختند. کودکان دارای اختلال شدید نوشتن یا خواندن در مناطق فرونتال زمانی مغز نگاره، دارای فعالیت‌های زیاد دلتا و کودکان دارای اختلالات با شدت کمتر دارای فعالیت‌های تنای بیشتر و فعالیت‌های آلفای وابسته کمتر بودند. مطالعه در مورد رابطه بین متغیرهای کمی مغز نگاره (EEG) و IQ دانش بیشتری در مورد جنبه‌های زیستی اختلالات یادگیری را ارائه کرد [۸]. Wu و همکاران (۲۰۰۶) به کارگیری ANN و SVM برای اولین بار مدلی مبتنی بر تکنیک‌های نرم‌افزاری برای تشخیص اختلال یادگیری ارائه کردند. آن‌ها در تحقیق خود با مقایسه عملکرد ANN و SVM به این نتیجه رسیدند که در صورت انتخاب ویژگی‌های مناسب در طبقه‌بندی اختلال‌های یادگیری، ANN عملکرد بهتری نسبت به SVM دارد [۹]. Wu و همکاران (۲۰۰۸) با توجه به نتیجه به دست آمده از تحقیق قبلی و با استفاده از الگوریتم ژنتیک برای انتخاب ویژگی، مدل ارائه‌شده خود را بهبود بخشیدند. آن‌ها در مدل پیشنهادی از ANN به عنوان طبقه‌بندی کننده و از الگوریتم ژنتیک به عنوان الگوریتم انتخاب ویژگی استفاده کردند [۱۰]. Nanni و Lumini (۲۰۰۹) با استفاده از مجموعه‌ای از طبقه‌بندی کننده‌ها و مقایسه عملکرد آن‌ها، مدلی برای طبقه‌بندی اختلال یادگیری ارائه کردند. آن‌ها در تحقیق خود انواع مختلفی از طبقه‌بندی کننده‌ها را مورد آزمایش قرار دادند. بهترین نتایج در این تحقیق با استفاده از LDC که یک طبقه‌بندی کننده از نوع تفکیک کننده خطی است و متد IDE با الگوریتم انتقال ICA برای انتخاب ویژگی مناسب به دست آمد [۱۱]. Muangnak و همکاران (۲۰۱۰) به مقایسه روش درخت تصمیم با Naïve Bayes که یک روش طبقه‌بندی بر پایه احتمال است در طبقه‌بندی اختلال یادگیری پرداختند. آن‌ها بیان کردند که نتایج به دست آمده از روش درخت تصمیم بهتر از نتایج روش Naïve Bayes است [۱۲]. Julie و Kannan (۲۰۱۰) از درخت تصمیم برای استخراج قوانین طبقه‌بندی و پیش‌بینی اختلال یادگیری استفاده کردند. آن‌ها با استفاده از درخت تصمیم موفق شدند تعداد ۷ قانون برای طبقه‌بندی اختلال‌های یادگیری استخراج نمایند [۱۳]. Wu و همکاران (۲۰۱۰) با به کارگیری روش‌های موازی سازی مدلی برای سریع تر شدن، فرایند طبقه‌بندی ارائه کردند. آن‌ها توانستند با به کارگیری روش‌های موازی سازی ضمن کاهش زمان تشخیص، دقت تشخیص را نیز افزایش دهند [۱۴]. Manghirmalani و همکاران (۲۰۱۱) موفق به ارائه یک روش نرم‌افزاری با استفاده از تکنیک LVQ جهت تشخیص اختلال یادگیری شدند. آن‌ها در مدل پیشنهادی خود توانستند علاوه بر تشخیص اختلال یادگیری انواع آن را نیز تعیین کنند [۱۵]. Wu و همکاران (۲۰۱۱) با به کارگیری الگوریتم جستجوی گویای موازی ناهمگون توانستند طبقه‌بندی کننده ANN را بهبود ببخشند [۱۶]. Manghirmalani و همکاران (۲۰۱۲) با استفاده از یک سیستم فازی موفق به طبقه‌بندی انواع اختلال یادگیری شدند [۱۷]. Jain و همکاران

جدول ۱- ویژگی‌های خودمراقبتی ICF-CY به کار گرفته شده در این

پژوهش

ویژگی	کد	تعداد و حالت هر ویژگی	
شستشوی خود	d 5100	7	{0,1,2,3,4,8,9}
	d 5101		
	d 5102		
مراقبت از اعضای بدن	d 5200	7	{0,1,2,3,4,8,9}
	d 5201		
	d 5202		
	d 5203		
	d 5204		
	d 5205		
توالیت کردن	d 53000	7	{0,1,2,3,4,8,9}
	d 53001		
	d 53010		
	d 53011		
لباس پوشیدن	d 5400	7	{0,1,2,3,4,8,9}
	d 5401		
	d 5402		
	d 5403		
	d 5404		
غذا خوردن	d 5500	7	{0,1,2,3,4,8,9}
	d 5501		
نوشیدن	d 5600	7	{0,1,2,3,4,8,9}
	d 5602		

برای این منظور ابتدا فرم‌هایی جهت جمع‌آوری ویژگی‌های خودمراقبتی کودکان ناتوان جسمی- حرکتی مطابق با چارچوب ICF-CY تهیه شد. سپس این فرم‌ها به کارشناس کاردرمانی یک آموزشگاه تخصصی کودکان ناتوان جسمی- حرکتی است، داده شد. پس از تکمیل این فرم‌ها کودکان مورد مطالعه در این تحقیق توسط یک کارشناس دیگر کاردرمانی مورد معاینه قرار گرفتند و مطابق با جدول ۲ گروه‌بندی شدند. در پایان با استفاده از فرم‌های شاخص‌های خودمراقبتی ICF-CY و همچنین فرم-های گروه‌بندی حاصل از معاینات تخصصی تهیه شد. این گروه‌بندی توسط کارشناسان کاردرمانی و به منظور تعیین نوع درمان تعریف می‌گردد. در این مجموعه داده حالت‌های هر سطح از خصوصیات به‌عنوان یک ویژگی مجزا در نظر گرفته شد و معیار سن و جنسیت به آن اضافه گردید؛ بنابراین در نهایت این مجموعه داده یک جدول شامل اطلاعات ۷۰ نمونه با مجموع ۱۵۷ ویژگی است که به ازای هر فرد یک سطر با ۱۵۷ ستون در نظر گرفته می‌شود و ستون آخر معرف گروهی است که آن فرد در آن قرار می‌گیرد. اگر فرد آزمایش‌شونده دارای یک ویژگی باشد در ستون مربوطه عدد ۱ و اگر فاقد آن ویژگی باشد در ستون مربوطه عدد ۰ درج می‌شود. جدول ۱ نشان‌دهنده ویژگی‌های بررسی‌شده با کدهای چارچوب ICF-

(۲۰۱۴) با به‌کارگیری ANN و LVQ مدلی جهت تشخیص اختلال یادگیری ارائه کردند. محققین در این پژوهش موفق شدند مدلی ارائه دهند تا علاوه بر تشخیص اختلال یادگیری، نوع آن را نیز مشخص نماید. آن‌ها با استفاده از یک سیستم فازی موفق به استخراج ۷ قانون برای طبقه‌بندی انواع اختلال یادگیری شدند [۱۸].

۲-۲-۲- تشخیص و طبقه‌بندی اختلال بیش فعالی

Tenev و همکاران (۲۰۱۴) با استفاده از SVM و EEG که یک روش برای ثبت مغز نگاره‌ها است مدلی جهت طبقه‌بندی بیش فعالی ارائه کردند. در این روش محققین از طیف توان EEG که از سیگنال‌های EEG ثبت‌شده نمونه‌ها، به‌دست‌آمده استفاده کردند. در این مدل داده‌ها در ۴ وضعیت مختلف جمع‌آوری می‌شوند: چشم‌باز، چشم‌بسته، آزمون عملکرد مداوم تصویری و آزمون عملکرد مداوم عاطفی. مجموعه داده نهایی به ۴ بخش مجزا تقسیم شده و هر یک از این مجموعه داده‌ها به یک SVM داده می‌شود. در نهایت نتایج به‌دست‌آمده از SVM ها به یک رأی گیرنده اکثریت داده می‌شود و نتیجه نهایی مطابق با خروجی رأی گیرنده اکثریت تعیین می‌گردد. با این روش آن‌ها با بررسی مغز نگاره‌ها توانستند وجود اختلال بیش فعالی را تشخیص دهند [۱۹].

۲-۲-۳- تشخیص و طبقه‌بندی مشکلات کاردرمانی

Yeh و همکاران (۲۰۱۲) با استفاده از ANN یک مدل برای طبقه‌بندی برخی از مشکلات کاردرمانی ارائه کردند. در این تحقیق از شبکه پرسپترون چندلایه با انتشار روبه عقب به‌عنوان طبقه‌بندی کننده استفاده شد. آن‌ها همچنین با به‌کارگیری الگوریتم CART که یکی از پرکاربردترین الگوریتم‌ها در درخت تصمیم است، موفق به استخراج قوانین طبقه‌بندی مدل خود شدند. محققین در این تحقیق با این روش دریافته‌اند، با اینکه در تشخیص مشکلات کاردرمانی، ۱۲۷ ویژگی مورد بررسی قرار می‌گیرد ولی در واقع ۹ ویژگی وجود دارند که نقش کلیدی و مهم در تشخیص این مشکلات را دارند [۲۰].

۳- مجموعه پارامترها

همان‌طور که در مقدمه بیان شد چارچوب ICF-CY یک استاندارد طبقه‌بندی چندمنظوره برای استفاده در زمینه‌های گوناگون است. یکی از موضوعات مطرح‌شده در این استاندارد موضوع خودمراقبتی است. طبق این استاندارد، خودمراقبتی به‌صورت فعالیت‌هایی نظیر شستشوی لباس، خشک کردن خود، لباس پوشیدن، خوردن و نوشیدن و مراقبت از سلامتی فرد تعریف شده است و برای آن سطوح مختلفی در نظر گرفته شده است. یکی از بزرگ‌ترین چالش‌های این تحقیق عدم دسترسی به مجموعه داده‌های استاندارد متناسب با کشور ایران بود. به همین منظور ما یک مجموعه داده طبق فصل خودمراقبتی استاندارد ICF-CY برای کودکان ناتوان جسمی - حرکتی ایجاد کردیم. در همین راستا اطلاعات مربوط به ۷۰ کودک ناتوان جسمی- حرکتی با توجه به معیارهای خود مراقبتی استاندارد ICF-CY و با روش نمونه‌گیری آسان جمع‌آوری شد.

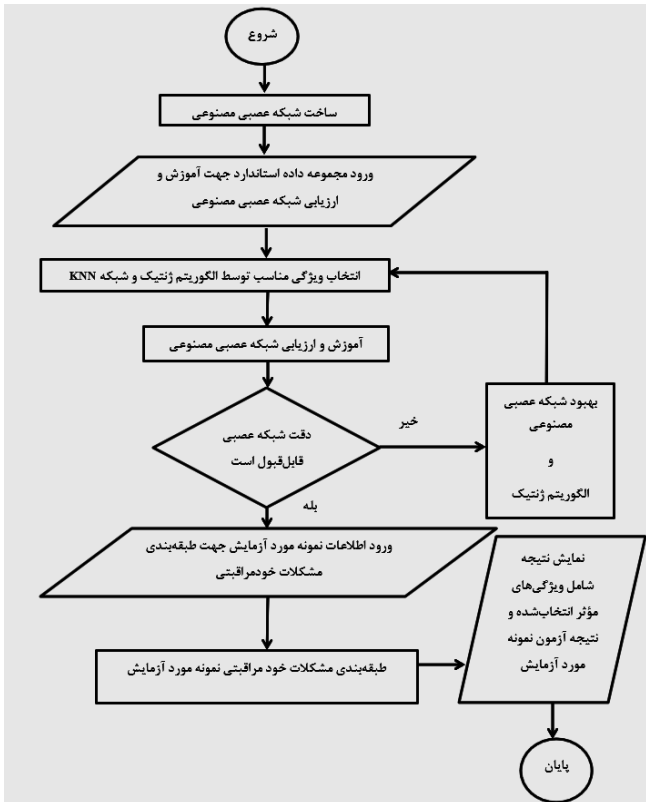
CY است. گروه‌های هدف نیز در جدول ۲ نمایش داده شده‌اند. هدف سیستم پیشنهادی طبقه‌بندی صحیح کودکان معلول جسمی - حرکتی در این گروه‌ها است.

جدول ۲ - گروه‌های هدف طبقه‌بندی

شماره گروه	توضیحات
۱	مشکل مراقبت از اعضای بدن
۲	مشکل توالیت کردن
۳	مشکل لباس پوشیدن
۴	مشکل شستشوی خود، مراقبت از اعضای بدن و لباس پوشیدن
۵	مشکل شستشوی خود، مراقبت از اعضای بدن، توالیت کردن و لباس پوشیدن
۶	مشکل غذا خوردن، نوشیدن، شستشوی خود، مراقبت از اعضای بدن، توالیت کردن و لباس پوشیدن
۷	بدون مشکل

۴- مدل پیشنهادی

با توجه به بررسی روش‌های ارائه‌شده و همچنین با در نظر گرفتن نقاط ضعف و قوت هریک از روش‌های مذکور، سیستمی می‌تواند برای طبقه‌بندی مشکلات خودمراقبتی کودکان مناسب باشد که در حین سادگی از دقت بالایی برخوردار باشد. برای این منظور پیشنهاد می‌شود از روش‌های مختلف و به‌صورت ترکیبی برای پوشش دادن نقاط ضعف و بهره‌گیری از نقاط قوت آن‌ها استفاده شود. در این مدل از روش‌های مبتنی بر نرم‌افزار جهت تشخیص و طبقه‌بندی مشکلات خودمراقبتی کودکان استفاده شده است. به علت اینکه سیستم‌های مبتنی بر پردازش سیگنال نیاز به شرایط خاص و تجهیزات ویژه دارند و این امر موجب محدودیت در استفاده از آن‌ها در نقاط مختلف می‌شود، استفاده از آن‌ها به‌عنوان یک سیستم کاربردی توصیه نمی‌شود. در این مدل از یک شبکه عصبی مصنوعی ترکیبی با الگوریتم ژنتیک جهت طبقه‌بندی مشکلات خودمراقبتی کودکان ناتوان جسمی - حرکتی استفاده می‌شود. علت به‌کارگیری الگوریتم ژنتیک در این سیستم، دستیابی به مجموعه‌ای کوچک اما مؤثر از ویژگی‌ها جهت طبقه‌بندی مشکلات خودمراقبتی کودکان است. انتخاب ویژگی‌های مؤثر موجب کاهش در هزینه‌های پیاده‌سازی و صرفه‌جویی در زمان خواهد شد. سیستم خبره پیشنهادی قادر به طبقه‌بندی هوشمند مشکلات خودمراقبتی کودکان، با استفاده از مجموعه کوچکی از خصوصیات است. با توجه به اینکه این سیستم از تکنیک‌های نرم‌افزاری استفاده می‌کند به راحتی در مناطق مختلف و بر روی ساختارهای متفاوت قابل پیاده‌سازی و استفاده است. شکل ۱ نشان‌دهنده نحوه عملکرد سیستم پیشنهادی است.



شکل ۱ - نحوه عملکرد سیستم پیشنهادی


۴-۱ - نحوه عملکرد سیستم هوشمند پیشنهادی

ابتدا یک شبکه عصبی مصنوعی ساخته می‌شود. سپس یک مجموعه داده استاندارد شامل اطلاعات افراد بر اساس شاخص‌های خودمراقبتی استاندارد ICF-CY به سیستم داده می‌شود. در مرحله بعد ویژگی‌های مناسب توسط الگوریتم ژنتیک تعیین و انتخاب می‌گردد. در تابع برازش الگوریتم ژنتیک از الگوریتم KNN برای ارزیابی شاخص برازندگی استفاده شده است. سپس شبکه عصبی مصنوعی با مجموعه داده جدید که فقط دارای ویژگی‌های منتخب است مورد آموزش و ارزیابی قرار می‌گیرد. اگر نتیجه ارزیابی قابل قبول نبود پارامترهای شبکه عصبی مصنوعی، الگوریتم ژنتیک و الگوریتم KNN جهت بهبود تغییر می‌یابد و به مرحله انتخاب ویژگی بازمی‌گردد. اگر نتیجه ارزیابی قابل قبول بود شبکه به‌دست‌آمده جهت طبقه‌بندی موارد مشکوک مورد استفاده قرار می‌گیرد و ویژگی‌های به‌دست‌آمده از اجرای الگوریتم ژنتیک به‌عنوان مجموعه ویژگی‌های مؤثر استخراج می‌شود.

۴-۲ - پیاده‌سازی، آزمون‌ها و نتایج

برای پیاده‌سازی سیستم پیشنهادی از نرم‌افزار MATLAB نسخه ۲۰۱۴ استفاده شده است. جهت ارزیابی این سیستم دو مرحله آزمون به‌صورت زیر در نظر گرفته شده است.

انتخاب ویژگی، یک شبکه عصبی مصنوعی چندلایه با استفاده از مجموعه داده جدید که با توجه به ویژگی‌های انتخاب‌شده و با تغییر مجموعه داده اصلی به دست آمده است مورد آموزش و ارزیابی قرار گرفت. برای آموزش و ارزیابی شبکه عصبی از روش 10-Fold Cross-validation استفاده شد.



شکل ۲- نمودار bestfitness

نتایج به دست آمده در مرحله دوم آزمون‌ها در جدول ۵ نمایش داده شده است. بهترین نتیجه در این مرحله متعلق به آزمون ۳-۲ با ۹۳/۴ درصد موفقیت و تعداد ۵۶ ویژگی مؤثر است.

جدول ۵- نتایج آزمون مرحله دوم

شماره آزمون	۱-۲	۲-۲	۳-۲	۴-۲
تعداد نسل اولیه	۱۰	۱۵	۲۰	۱۷
آخرین نسل	۵۰	۵۰	۱۰۰	۱۰۰
تعداد نوروں‌های لایه میانی	۴۰	۷۰	۲۷	۴۵
تعداد ویژگی	۸۸	۱۴۵	۵۶	۹۶
میزان موفقیت	۶۳/۸	۸۴/۸	۹۳/۴	۷۶/۶

۵- نتیجه‌گیری و پیشنهادها

در این پژوهش ما تلاش کردیم با به‌کارگیری شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک ضمن انتخاب ویژگی مؤثر یک روش جدید جهت طبقه‌بندی مشکلات خودمراقبتی دانش‌آموزان ناتوان جسمی- حرکتی ارائه دهیم. در این تحقیق ابتدا یک شبکه عصبی با مجموعه داده اولیه ارائه شد. سپس ما توانستیم با به‌کارگیری الگوریتم ژنتیک و الگوریتم KNN ویژگی‌های مؤثر را انتخاب کنیم و با استفاده از یک شبکه عصبی مدلی جهت طبقه‌بندی مشکلات خودمراقبتی دانش‌آموزان ناتوان جسمی- حرکتی ارائه نماییم. بهترین نتایج در روش اول مربوط به آزمایش ۴-۱ است که در آن، یک شبکه عصبی مصنوعی چندلایه با تعداد ۶۰ نوروں در لایه میانی و با در نظر گرفتن ۱۵۶ ویژگی موجود در مجموعه داده اصلی،

مرحله اول: در این مرحله ۴ آزمون برگزار شد و نتایج آن جمع‌آوری گردید. در این چهار آزمون از یک شبکه عصبی مصنوعی چندلایه برای طبقه‌بندی مجموعه داده مذکور استفاده شد. برای آموزش و ارزیابی شبکه عصبی از روش 10-Fold Cross-validation استفاده شد. هدف این آزمون دست-یابی به یک شبکه عصبی مصنوعی با بالاترین بازدهی بود. هر آزمون با توجه به نتایج قبلی و با تغییر پارامترهای شبکه عصبی انجام شد. نتایج هر آزمون در جدول ۳ نشان داده شده است. همان‌طور که مشخص است بهترین نتیجه در این مرحله مربوط به یک شبکه عصبی چندلایه با تعداد ۶۰ نوروں لایه میانی و دقت ۹۱/۶ درصد برای مجموعه تست است.

جدول ۳- نتایج آزمون مرحله اول

شماره آزمون	تعداد نوروں‌های لایه میانی	درصد موفقیت	تعداد ویژگی
۱-۱	۱۰	۶۵/۳	۱۵۶
۲-۱	۳۰	۷۳/۶	۱۵۶
۳-۱	۵۰	۸۲/۴	۱۵۶
۴-۱	۶۰	۹۱/۶	۱۵۶

مرحله دوم: هدف این مرحله کاهش تعداد ویژگی‌های استفاده‌شده از طریق انتخاب ویژگی مؤثر با استفاده از الگوریتم ژنتیک و دست‌یابی به دقت قابل قبول در طبقه‌بندی بود. در این مرحله از تابع ga نرم‌افزار MATLAB برای پیاده‌سازی الگوریتم ژنتیک استفاده شد. تعداد نسل اولیه در هر مرحله از آزمون به‌طور جداگانه تعیین می‌گردد. تعداد ژن‌های نسل اولیه به‌صورت تصادفی از ترکیب ویژگی‌ها توسط یک تابع تولید می‌شود. تابع برازش با استفاده از الگوریتم KNN که در آن مقدار $K=1$ در نظر گرفته‌شده، ایجاد گردید. معیار برازندگی، نسبت خطاهای رخ داده به ویژگی‌های انتخاب‌نشده در نظر گرفته شد. سایر پارامترهای تابع ga در جدول ۴ نمایش داده شده است.

جدول ۴- پارامترهای تابع ga

نام پارامتر	تابع به‌کاررفته شده
PopulationType	Bitstring
SelectionFcn	Selectionuniform
MutationFcn	Mutationuniform
CrossoverFcn	CrossoverScattered

شکل ۲ نمودار bestfitness آزمون ۴ از مرحله دوم را نمایش می‌دهد. این نمودار نمایانگر میانگین و بهترین نتیجه تابع برازش در هر نسل است که در اینجا برای نمونه، نمودار مربوط به آزمون ۴ نمایش داده می‌شود. پس از

- [8] S. Asseondi, S. Casarotto, A. Bianchi, G. Chiarenza, Y. D'Asseler, and I. Lemahieu, "Automatic measurement of reading related potentials in dyslexia," in *IEEE Benelux EMBS Symposium, Belgian Day on Biomedical Engineering*, pp. 7-8, 2006.
- [9] T.-K. Wu, "Identifying and diagnosing students with learning disabilities using ANN and SVM," in *Neural Networks, IJCNN'06. International Joint Conference on*, pp. 4387-4394, 2006.
- [10] T.-K. Wu, S.-C. Huang, and Y.-R. Meng, "Evaluation of ANN and SVM classifiers as predictors to the diagnosis of students with learning disabilities," *Expert Systems with Applications*, vol. 34, pp. 1846-1856, 2008.
- [11] L. Nanni and A. Lumini, "Ensemble generation and feature selection for the identification of students with learning disabilities," *Expert Systems with Applications*, vol. 36, pp. 3896-3900, 2009.
- [12] N. Muangnak, W. Pukdee, and T. Hengsanunkun, "Classification students with learning disabilities using naive bayes classifier and decision tree," in *Networked Computing and Advanced Information Management (NCM) , Sixth International Conference on*, pp. 189-192, 2010.
- [13] M. D. Julie and B. Kannan, "Prediction of learning disabilities in school age children using decision tree," in *Recent Trends in Networks and Communications*, ed: Springer, pp. 533-542, 2010.
- [14] T.-K. Wu, S.-C. Huang, Y.-L. Lin, H. Chang, and Y.-R. Meng, "On the parallelization and optimization of the genetic-based ANN classifier for the diagnosis of students with learning disabilities," in *Systems Man and Cybernetics (SMC), IEEE International Conference on*, pp. 4263-4269, 2010.
- [15] P. Manghirmalani, Z. Panthaky, and K. Jain, "Learning disability diagnosis and classification-A soft computing approach," in *Information and Communication Technologies (WICT), World Congress on*, pp. 479-484, 2011.
- [16] T.-K. Wu, S.-C. Huang, W.-W. Chiou, and Y.-R. Meng, "Customizing asynchronous parallel pattern search algorithm to improve ANN classifier for learning disabilities students identification," in *Natural Computation (ICNC), Seventh International Conference on*, pp. 1639-1643, 2011.
- [17] P. Manghirmalani, D. More, and K. Jain, "A fuzzy approach to classify learning disability," *Int. J. Adv. Res. Artif. Intell*, vol. 1, 2012.
- [18] K. Jain, P. M. Mishra, and S. Kulkarni, "A Neuro-Fuzzy Approach to Diagnose and Classify Learning Disability," in *Proceedings of the Second International Conference on Soft Computing for Problem Solving , December 28-30*, pp. 645-657, 2014.
- [19] A. Tenev, S. Markovska-Simoska, L. Kocarev, J. Pop-Jordanov, A. Müller, and G. Candrian, "Machine learning approach for classification of ADHD adults," *International Journal of Psychophysiology*, vol. 93, pp. 162-166, 2014.
- [20] Y.-L. Yeh, T.-H. Hou, and W.-Y. Chang, "An intelligent model for the classification of children's occupational therapy problems," *Expert Systems with Applications*, vol. 39, pp. 5233-5242, 2012.

به‌دقت ۹۱/۶ درصد دست پیدا کرد. در روش دوم ما توانستیم با کمک الگوریتم ژنتیک در بهترین حالت تعداد ۱۵۶ ویژگی را به ۵۶ ویژگی کاهش دهیم و به‌دقت ۹۳/۴ درصد در آزمون ۲-۳ دست پیدا کنیم. بررسی این نتایج نشان می‌دهد:

۱- با استفاده از شبکه‌های عصبی به همراه الگوریتم ژنتیک می‌توان مدلی جهت طبقه‌بندی مشکلات خودمراقبتی کودکان ناتوان جسمی - حرکتی ارائه کرد.

۲- انتخاب ویژگی در این تحقیق مشخص کرد که باینکه در طبقه‌بندی مشکلات مذکور ۱۵۷ ویژگی موردبررسی قرار می‌گیرد ولی در واقع ۵۶ عدد از این حالت‌ها بیشترین تأثیر در این طبقه‌بندی را دارند. در واقع با انتخاب ویژگی صحیح می‌توان در زمان و سایر هزینه‌ها صرفه‌جویی کرد.

پیشنهاد می‌شود در آینده جهت بهبود مدل پیشنهادی از الگوریتم‌های تکاملی دیگر و همچنین از سایر طبقه‌بندی کننده‌ها برای بهبود مدل پیشنهادی استفاده شود.

۶- سپاسگزاری

در اینجا لازم است از کارشناسان آموزشگاه ضربایی یزد مخصوصاً جناب آقای دهقانی‌زاده و سرکار خانم کلانتر که با کمک‌های بی‌شائبه خود امکان انجام این پژوهش را فراهم آوردند تشکر و قدردانی نمائیم. بی‌شک بدون تلاش‌های مستمر ایشان، تهیه مجموعه داده استاندارد استفاده‌شده در این پژوهش امکان‌پذیر نبود.

مراجع

- [۱] م. حیدری‌پور، ع. مشهدی و م. اصغری نکاح، "رابطه هوش هیجانی، کیفیت زندگی و ویژگی‌های شخصیتی با سلامت روان در افراد با معلولیت (ناتوانی) جسمی حرکتی" توانبخشی، دوره ۱۴، شماره ۱، بهار ۱۳۹۲.
- [۲] انصیری‌پور، ج. طیبی، افکار و م. کمالی، "بررسی تأثیر اجرای برنامه توان‌بخشی مبتنی بر جامعه بر وضعیت زندگی معلولان در ایران"، مجله دانش و تندرستی، دوره ۷، شماره ۴، زمستان ۱۳۹۱.
- [3] R. L. Brown and R. J. Turner, "Physical disability and depression: clarifying racial/ethnic contrasts," *Journal of aging and health*, 2010.
- [4] W .H. Organization, *International Classification of Functioning, Disability, and Health: Children & Youth Version: ICF-CY*: World Health Organization, 2007.
- [5] P. Mico-Tormos, D. Cuesta-Frau, and D. Novak, "Early Dyslexia Detection Techniques by means of Oculographic Signals," in *2nd European Medical & Biological Engineering Conference, Vienna, Austria*, 2002.
- [6] D. Novak, P. Kordik, M. Macaš, M. Vyhnaek, R. Brzezny, and L. Lhotska, "School children dyslexia analysis using self organizing maps," in *Engineering in Medicine and Biology Society, 2004. IEMBS'04. 26th Annual International Conference of the IEEE*, 2 pp. 1-4, 2004.
- [7] L. C. Fonseca, G. M. Tedrus, M. G. Chiodi, J. N. Cerqueira, and J. M. Tonelotto, "Quantitative EEG in children with learning disabilities: analysis of band power," *Arquivos de neuro-psiquiatria*, vol. 64, pp. 376-381, 2006.