

بهینه سازی مدل شبکه عصبی RBF و روش ماشین بردار پشتیبان در تشخیص اختلال وسواس

معصومه السادات موسوی^۱، سید سعید آیت^۲

^۱ کارشناسی ارشد، مهندسی کامپیوتر، دانشگاه پیام نور، تهران، ایران، yekta.۱۳۶۲@gmail.com

^۲ دانشیار، گروه علمی مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه پیام نور، dr.ayat@pnu.ac.ir

چکیده

انتخاب روش مناسب برای مدل سازی و تحلیل داده های پزشکی، بسیار مهم و در مواردی بسیار حساس است. تحقیق حاضر با توجه به کاربرد شبکه عصبی مصنوعی در تشخیص بیماری، به گوشه ای دیگر از قدرت های شبکه عصبی مصنوعی پرداخته است. با توجه به شیوع اختلال وسواس تشخیص این اختلال به کمک دو مدل ماشین بردار پشتیبان و شبکه عصبی RBF انجام شده است. عملیات تشخیص این اختلال با دسترس بودن اطلاعات اخذ شده از بررسی پرونده های موجود در مراکز روانپزشکی، مصاحبه با روانپزشکان و افراد بیمار و توزیع پرسشنامه مادزلی در میان ۶۲۱ فرد بیمار و سالم جمع آوری شده است. ورودی های شبکه یا به عبارتی پارامترهای مؤثر این بیماری در چارچوب ۳۳ پارامتر جمع آوری شده اند. نتایج نشان می دهد که با استفاده از ۸۰ درصد داده ها جهت آموزش شبکه، مدل RBF دارای خطای بسیار کمتری نسبت به روش SVM می باشد، به طوریکه با تغییر در پارامتر ضریب گسترش، این شبکه توانست خطای تشخیص را به کمتر از ۱٪ برساند که به عنوان یک تشخیص اولیه مناسبی می باشد.

واژگان کلیدی: اختلال وسواس؛ شبکه عصبی مصنوعی (ANN)؛ ماشین بردار پشتیبان (SVM)؛ شبکه عصبی (RBF)

۱. مقدمه

در برخی موارد از شبکه های عصبی مصنوعی^۱ به عنوان ابزاری کارا در شناسایی الگوهای پزشکی استفاده شده است. این شناسایی به طرق مختلف صورت می گیرد. در استفاده از شبکه های عصبی مسئله اساسی داشتن اطلاعاتی است که شبکه توسط آن آموزش داده می شود و نیز داده هایی برای تست شبکه حاصل مورد نیاز است تا بتوان میزان صحت و درستی شبکه را مورد آزمون قرار داد. (مهمونی و تبریزی و کمرطلایی، ۲۰۱۱)

وسواس یکی از اختلالاتی است که در حال حاضر افراد بسیار زیادی در سراسر جهان آن را تجربه کرده و یا در خطر ابتلا به آن قرار دارند. بدین منظور، پیش بینی این اختلال از اهمیت بالایی برخوردار است. باید سعی شود از آن دسته مدل هایی استفاده کرد که تشخیص بر اساس آن ها دارای حداقل خطا و حداکثر اطمینان باشد.

^۱ - Artificial Neural Network

در اینجا هدف انتخاب یک ساختار بهینه، به منظور کاهش میزان خطای تشخیص اختلال وسواس می‌باشد. در این راستا این مطالعه در نظر دارد خطای تشخیص اختلال وسواس را با استفاده از دو مدل ماشین بردار پشتیبان^۱ و شبکه عصبی تابع پایه شعاعی^۲ به حداقل برساند و مقایسه‌ای از مقادیر محاسبه شده‌ی دو مدل را ارائه دهد.

در دو دهه اخیر با رشد تکنولوژی کامپیوتری در حوزه پزشکی، تشخیص دقیق و به هنگام انواع بیماری‌ها با استفاده از تکنولوژی‌های نوین نقش اساسی و حیاتی برای جامعه‌ی پزشکی ایفا کرد. (Djavan, & et al., ۲۰۰۲) الگوریتم‌های شبکه عصبی مصنوعی به طور گسترده در تجهیزات پزشکی و متدهای تشخیص استفاده شده است. شبکه‌های عصبی مصنوعی به شکل وسیعی در تشخیص الگو^۳ استفاده شده و به صورت موفقیت‌آمیز در طبقه‌بندی‌های پزشکی به کار گرفته شده‌اند. (Dolgobrodov, & et al., ۲۰۰۷) شبکه‌های عصبی مصنوعی در حل مسائل مربوط به تشخیص بالینی، آنالیز تصاویر پزشکی، تشخیص از روی تصاویر پزشکی، تشخیص بیماری‌های ذهنی یا روانی، پیش‌بینی بقا، ناباروری و جراحی به کار رفته است. به عنوان نمونه برخی از مطالعات از شبکه عصبی مصنوعی در مباحث مختلف مربوط به بیماری قلب استفاده نموده‌اند. در مقاله‌ای با عنوان کاربرد شبکه عصبی مصنوعی در تعیین پیش‌بینی کننده‌های مهم مرگ و میر درون بیمارستانی پس از جراحی قلب باز و مقایسه‌ی آن با مدل رگرسیون لجستیک و مقایسه حساسیت‌ها و ویژگی‌های این دو مدل مشخص شد که شبکه عصبی مصنوعی در حل مسائل از مدل رگرسیون لجستیک توانا تر می‌باشد. (بیگلریان و بابایی و عزمی، ۱۳۸۳) در مقاله‌ای دیگر که با هدف مقایسه‌ی شبکه عصبی مصنوعی و رگرسیون کاکس در پیش‌بینی بقای بیماران مبتلا به سرطان معده انجام شده بود، شبکه عصبی مصنوعی نسبت به مدل رگرسیون کاکس پیش‌بینی بهتری برای بقای بیماران داشت و به‌کارگیری شبکه عصبی مصنوعی در زمینه‌های پیش‌بینی بقا پیشنهاد شد. (بیگلریان و حاجی‌زاده و کاظم‌نژاد، ۲۰۱۲)

در مقاله دیگری با عنوان تشخیص بیماری پارکینسون با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان دیوید گیل^۴ و همکاران، به مقایسه ساختارهای مختلفی از شبکه‌های مصنوعی و ماشین بردار پشتیبان (SVM) در تشخیص این بیماری پرداخته‌اند که در آن کارایی شبکه تخمین زده شده است و به قابلیت بالایی از اطمینان رسیده‌اند. (گیل و جانسون، ۲۰۰۹)

نشاط و همکاران در پژوهشی با عنوان طراحی سیستم خبره تشخیص اختلالات کبدی با استفاده از شبکه‌های عصبی مصنوعی سیستم خبره طراحی نمودند که بیماری‌های کبد را تشخیص دهد. شبکه‌های مورد نظر در این پژوهش از نوع پرسپترون چند لایه و تابع پایه شعاعی بودند. بعد از آنالیز، شبکه پرسپترون چند لایه با دقت ۸۶/۲ درصد و تابع پایه شعاعی با دقت ۶۴/۳ درصد بیماری‌های کبدی را به درستی تشخیص می‌دادند. (نشاط و یعقوبی و نقیعی، ۲۰۰۹)

^۱ - Support Vector Machine

^۲ - Radial Basis Function

^۳ - Pattern Recognition


^۴ - David Gill

۲. ساختارهای پیاده سازی شده

۱.۲. تابع پایه شعاعی (RBF)

این شبکه‌ها اولین بار در سال ۱۹۸۸ توسط برومهدلو^۱ مطرح گشتند، این شبکه‌ها در واقع، یک شبکه مستقیم دو لایه هستند که لایه مخفی آنها از توابع گوسین^۲ عمل می‌نماید که این توابع با دو پارامتر مرکز گوسی واریانس یا میزان گسترده‌گی گوسی شناسایی می‌شوند.

لایه خارجی شبکه های RBF از توابع فعال سازی خطی بهره می‌برد که از این نظر، این شبکه‌ها را می‌توان شبیه شبکه‌های MLP^۳ دانست. (شکل شماره ۱). (Jain, & Mao, & Mohiuddin, ۱۹۹۶)



شکل شماره ۱. شبکه عصبی (RBF)

آموزش در شبکه‌های RBF در دو مرحله رخ می‌دهد. نخست، وزن‌های مرتبط کننده‌ی ورودی به لایه مخفی محاسبه می‌شوند و سپس، وزن‌های لایه مخفی به لایه خروجی مشخص می‌گردند. به طور کلی آموزش این شبکه‌ها بسیار سریع رخ می‌دهد و کارایی آن‌ها در بسیاری از مسائل مربوط به دسته‌بندی از کارایی شبکه‌های MLP بهتر است. شبکه‌های RBF نیازمند نوروں‌های بیشتری هستند و آموزش این نوع شبکه‌ها در مدت زمان کوتاه‌تری است و در صورتی که ورودی‌های بیشتری دریافت کند نتیجه حاصل مطلوب‌تر خواهد بود. (Rastogi, & Bhalla., ۲۰۱۴)

^۱ - Broomhead and Lowe

^۲ - Gaussian Functions


^۳ - Multi-layer Perceptron

۲.۲. ماشین بردار پشتیبان (SVM)

روش SVM، یک روش آماری غیرپارامتریک نظارت شده است و براساس این فرض عمل می‌کند که هیچ گونه اطلاعاتی از چگونگی توزیع مجموعه داده‌ها وجود نداشته باشد. (Mountrakis, & et al., ۲۰۱۱; Mantero, & et al., ۲۰۰۵) ماشین بردار پشتیبان، در واقع یک طبقه‌بندی کننده دودویی است که دو کلاس را با استفاده از یک مرز خطی از هم جدا می‌کند و وابسته به خانواده طبقه‌بندی‌های تعمیم یافته است. (Srivastava, & Bhambhu., ۲۰۰۹) ماشین بردار پشتیبان، داده‌ها را با عبور یک صفحه (مرز خطی) و با استفاده از تمامی باندها و به کارگیری یک الگوریتم بهینه‌سازی طبقه‌بندی می‌کند. بدین گونه که ابتدا نمونه‌هایی که مرز کلاس را تشکیل می‌دهند به دست می‌آیند. به عبارت دیگر تعدادی از نقاط آموزشی که کمترین فاصله تا مرز تصمیم‌گیری را دارند می‌توانند به عنوان بردار پشتیبان در نظر گرفته شوند. (Huang, & Shi, & Suykens., ۲۰۱۴) برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود. (Vapnik, & Chervonenkis., ۱۹۹۱) مرز خطی بین دو کلاس به گونه‌ای محاسبه می‌شود که:

الف) تمام نمونه‌های کلاس +۱ در یک طرف مرز و تمام نمونه‌های کلاس -۱ در طرف دیگر مرز واقع شوند. (شکل شماره ۲)

ب) مرز تصمیم‌گیری به گونه‌ای باشد که فاصله نزدیک‌ترین نمونه‌های آموزشی هر دو کلاس از یکدیگر، در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداکثر شود. (کشاورز و قاسمیان یزدی، ۱۳۸۴)



شکل شماره ۲: طبقه‌بندی به روش SVM در دو کلاس و با استفاده از کرنل خطی در دو بعد.

۳. نتایج و تحلیل‌ها

۱.۳. اخذ داده‌ها

۲.۳. انتخاب داده‌های تست و آموزش شبکه

هر شبکه برای به وجود آمدن و قابل قبول بودن به دو سری داده نیازمند است: داده‌های آموزش و داده‌های تست. طبق نتایج بررسی‌های به عمل آمده مطابق جدول شماره (۱) ۸۰ درصد داده‌ها جهت آموزش و مابقی جهت تست انتخاب می‌گردند و در ادامه کار همواره از این نسبت استفاده خواهد شد.

جدول ۱: بررسی نسبت آموزش به تست در دو ساختار

خطای تست شبکه	درصد آموزش	درصد تست	ساختار شبکه
۷/۰۴	۴۰	۶۰	RBF
۱۶/۴۴	۴۰	۶۰	SVM
۱۰/۹۵	۵۰	۵۰	RBF
۱۷/۸۰	۵۰	۵۰	SVM
۱۵/۰۳	۶۰	۴۰	RBF
۱۶/۰۸	۶۰	۴۰	SVM
۷/۵۲	۷۰	۳۰	RBF
۱۶/۴۸	۷۰	۳۰	SVM
۵/۱۲	۸۰	۲۰	RBF
۱۳/۵۵	۸۰	۲۰	SVM
۸/۹۸	۹۰	۱۰	RBF
۱۳/۸۵	۹۰	۱۰	SVM

۳.۳. انتخاب پارامتر بهینه در شبکه‌های RBF و ماشین بردار پشتیبان SVM

همان‌طور که گفته شد در حدود ۸۰ درصد داده‌ها جهت آموزش و مابقی جهت تست انتخاب می‌گردند. در این مسیر، پارامتر بهینه برای هر شبکه خاص به دست خواهند آمد. در طی فرآیند یادگیری میزان فراگیری شبکه توسط توابع هدف مرتباً سنجیده می‌شوند و در نهایت شبکه‌ای مورد پذیرش قرار می‌گیرد که دارای کمترین میزان خطا باشد. پارامتر تأثیرگذار در شبکه RBF پارامتر ضریب گسترش^۱ بوده که با توجه به اطلاعات ورودی و با سعی و خطا مقدار بهینه آن به دست خواهد آمد.

پارامتر تأثیرگذار در مدل ماشین بردار پشتیبان ساختار هسته می‌باشد که این تأثیر با تغییر در نوع تابع کرنل بررسی می‌گردد.

^۱ - Spread

۴.۳. نتایج حاصل از شبکه عصبی RBF

همان گونه که گفته شد پارامتر تأثیرگذار در شبکه RBF پارامتر ضریب گسترش بوده که جدول شماره ۲ نتایج خطا را برای مقادیر ضریب گسترش متفاوت نشان می دهد.

جدول ۲: نتایج مربوط به شبکه RBF با مقادیر ضریب گسترش متفاوت

خطای تست	ضریب گسترش
۰/۱	٪ ۲,۱۹
۰/۵	٪ ۰,۷۳
۰/۷	٪ ۱,۸۳
۱	٪ ۳,۲۹
۰/۳	٪ ۳,۶۶


همان طور که در جدول بالا می بینیم، با ضریب گسترش ۰/۳ شبکه با بیشترین خطا یعنی ۳/۶۶ درصد مواجه است. در صورتی که در شبکه، ضریب گسترش ۰/۵ خطا به ۰/۷۳ درصد کاهش می یابد. در شکل شماره ۳ نمودار کارایی^۱ این شبکه در زمانی که کمترین خطا وجود دارد یعنی شبکه دارای ضریب گسترش ۰/۵ می باشد، قابل مشاهده است.

^۱ - Performance

دومین همایش ملی مهندسی کامپیوتر و فناوری اطلاعات دانشگاه پیام نور

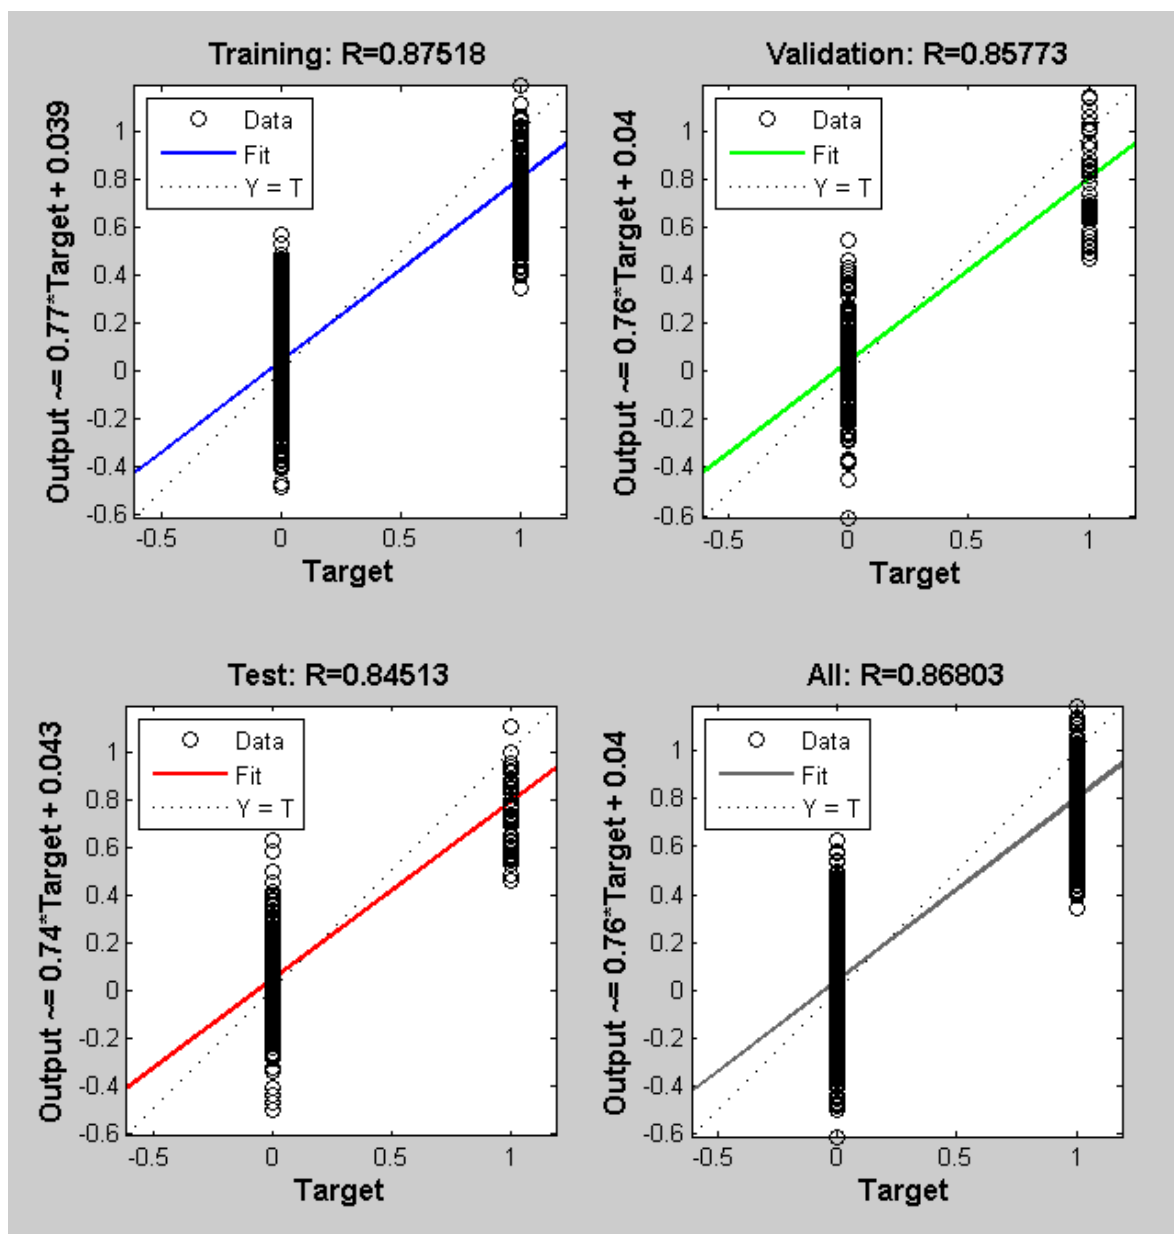
استان اصفهان، دانشگاه پیام نور مرکز نجف آباد

۱۴-۱۳ اسفند ماه ۱۳۹۴



شکل شماره ۳: نمودار Performance مدل RBF

نمودار کارایی نحوه کاهش خطاها را نشان می‌دهد. همان‌طور که مشاهده می‌گردد خطاهای خروجی نزدیک به هم بوده و شبکه قابل اطمینان است و در طی ۸ دوره آموزش شبکه، بهترین مقدار کارایی Validation برابر با ۰/۰۴ در دوره هفتم آموزش می‌باشد و بعد از این دوره به دلیل شکست شبکه، از ادامه آموزش جلوگیری شده و آموزش متوقف شده است. در شکل شماره ۴ نمودار رگرسیون مربوط به داده‌های مختلف شبکه نشان داده شده است.



شکل شماره ۴: نمودار رگرسیون مدل RBF

در این نمودار محور افقی مقادیر هدف را نشان می‌دهد و محور عمودی مقدار خروجی شبکه عصبی را نشان می‌دهد مقادیر خروجی در بازه [۰ و ۱] می‌باشد که هر چه این مقدار به ۱ نزدیک‌تر باشد بهتر است. اصولاً این نمودارها بایستی منطبق بر خط $y=T$ باشند که هر چقدر هدف ذخیره شده با مقدار خروجی یکسان باشد این انطباق بیشتر خواهد بود که در بررسی نمودارها همان گونه که مشاهده می‌گردد در نمودار رگرسیون براساس داده‌های Train این انطباق بیشتر بوده و مقدار رگرسیون برابر با ۰/۸۸ می‌باشد که بسیار به یک نزدیک می‌باشد. رگرسیون کل داده‌ها نیز برابر با ۰/۸۷ مشاهده می‌گردد.


۵.۳. نتایج حاصل از ساختار ماشین بردار پشتیبان (SVM)

همان‌گونه که مطرح شد پارامتر تأثیرگذار در ساختار ماشین بردار پشتیبان ساختار هسته می‌باشد که در جدول شماره ۳ نتایج عملیات تشخیص اختلال با ۵ نوع کرنل مختلف ثبت گردیده است.

جدول شماره (۳): بررسی تغییرات ساختار هسته برای مدل SVM

نوع تابع کرنل	خطای تست شبکه
Linear	٪ ۱۲/۸۲
Radial	٪ ۸۴/۲۴
Polynomial	٪ ۴۳/۹۵
Quadratic	٪ ۳۱/۱۳
Mlp	٪ ۴۳/۲۳

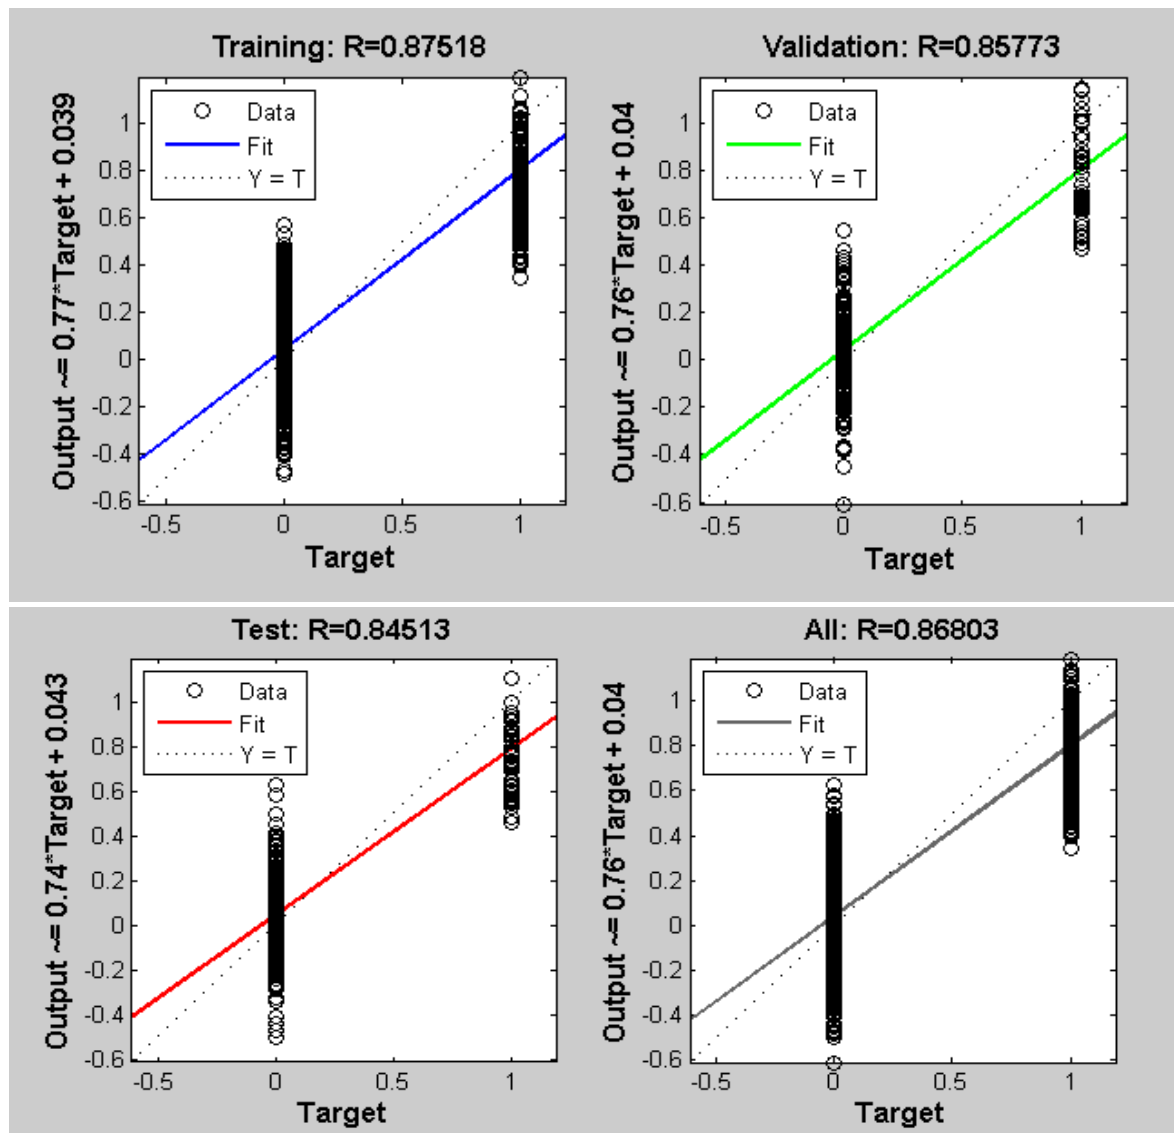
همان‌طور که مشاهده می‌گردد، با استفاده از ساختار Linear در هسته می‌توان بهترین جواب با خطای در حدود ۱۲/۸۲ درصد داشته باشیم، در شکل شماره ۵ نمودار کارایی این مدل نشان داده شده است.



شکل شماره ۵. نمودار Performance مدل SVM

همان‌گونه که نمودار نشان می‌دهد در طی ۱۴ دوره آموزش شبکه بهترین مقدار کارایی Validation، در مرحله هشتم آموزش و برابر با ۰/۰۳ می‌باشد و بعد از این دوره‌ی آموزش به دلیل شکست شبکه، آموزش متوقف شده است. همانگونه که مشاهده می‌شود در این نمودار همواره خط Train با افزایش دوره کاهش می‌یابد ولی خط مربوط به نمودارهای Validation و Test به تدریج با افزایش دوره پس از مرحله هشتم آموزش افزایش یافته‌اند. از این‌رو از ادامه آموزش جلوگیری و آموزش متوقف شده است.

در شکل شماره ۶ نمودار رگرسیون مربوط به داده‌های مختلف این مدل نشان داده شده است که همان‌گونه که قابل مشاهده می‌باشد، در نمودار رگرسیون براساس داده‌های Train انطباق بر خط $y=T$ بیشتر بوده و مقدار آن برابر با ۰/۸۸ می‌باشد که به یک بسیار نزدیک می‌باشد و رگرسیون کل نیز برابر با ۰/۸۷ مشاهده می‌گردد.



شکل شماره ۶ . نمودار رگرسیون مدل SVM

۶. نتیجه گیری

در این تحقیق، از واکنش افراد سالم و بیمار نسبت به ۳۳ پارامتر اختلال وسواس، نتایج حاصل از بررسی دو مدل، شبکه عصبی مصنوعی RBF و ساختار ماشین بردار پشتیبان SVM و مقایسه عملکرد این شبکه‌ها با یکدیگر و با نتایج حاصل از آزمایشات استفاده شد. بررسی‌های انجام شده نشان داد که شبکه RBF به دلیل دارا بودن مبنای تئوری قوی‌تر و قابلیت

تعمیم پذیری در حالت های مختلف آموزش و یادگیری دارای عملکرد مناسب تری بود. به طوری که استفاده از ۸۰ درصد داده ها جهت آموزش و تغییرات در پارامتر ضریب گسترش شبکه توانست خطای تشخیص اختلال را به کمتر از ۱ درصد برساند که این یک نتیجه مناسبی با استفاده از تکنیک شبکه عصبی مصنوعی در خصوص تشخیص این اختلال بود.

مراجع

بیگلریان، اکبر و بابایی، غلامرضا و عزمی، رضا. (۱۳۸۳). کاربرد مدل شبکه عصبی مصنوعی در تعیین پیش بینی کننده های مهم مرگ و میر درون بیمارستانی پس از جراحی قلب باز و مقایسه آن با مدل رگرسیون لجستیک. مجله علوم پزشکی مدرس، آسیب شناسی زیستی (علوم پزشکی مدرس)، ۷(۱): ۲۳-۲۹.

کشاوری احمد & قاسمیان یزدی محمدحسن. (۱۳۸۴). یک الگوریتم سریع مبتنی بر ماشین بردار پشتیبان برای طبقه بندی تصاویر ابرطیفی با استفاده از همبستگی مکانی. مهندسی برق و مهندسی کامپیوتر ایران، شماره ۳، ۴۴-۳۷.

Biglarian. A, Hajizadeh. E, Kazemnejad, A. N. O. U. S. H. I. R. A. V. A. N. (0202). Comparison Of Artificial Neural Network and Cox Regression Models In Survival Prediction Of Gastric Cancer Patients. Koomesh, 00(3), Pe002-Pe002.

Djavan, B., Remzi, M., Zlotta, A., Seitz, C., Snow, P., & Marberger, M. (0220). Novel artificial neural network for early detection of prostate cancer. Journal of Clinical Oncology, 02(4), 100-101.

Dolgobrodov, S. G., Moore, P., Marshall, R., Bittern, R., Steele, R. J. C., & Cuschieri, A. (0222). Artificial neural network: predicted vs. observed survival in patients with colonic cancer. Diseases of the colon & rectum, 22(0), 084-010.

Gil. D, Johnson. M. (0221). Diagnosing Parkinson By Using Artificial Neural Networks And Support Vector Machines. Global Journal of Computer Science And Technology, 1(4).

Huang, X., Shi, L., & Suykens, J. (0204). Support vector machine classifier with pinball loss. Pattern Analysis and Machine Intelligence, IEEE Transactions on, 33(2), 184-112

Jain, A. K., Mao, J., & Mohiuddin, K. M. (0113). Artificial neural networks: A tutorial. Computer, (3), 30-44.

Mantero P., Moser, G. and Serpico, S. B., 0222. Partially supervised classification of remote sensing mages through SVM-based probability density estimation. IEEE Trans. on Geoscience and Remote Sensing, 43, 221-222.

Mehmoei. N.R, Tabrizi. S.SH, Kamartalei. F. (0200). Software Designed To Detect Heart Disease In Patients Using Artificial Neural Networks. 0st National Conference On Soft Computing And Information Technology.

Mountrakis, G., Im., J. and Ogole, C., 0200. Support vector machines in remote sensing: A review. ISPRS Journal of Photogrammetry and Remote Sensing, 03, 042-021.

Neshat, M., Yaghobi, M., & Naghibi, M. (0221, July). Designing an expert system of liver disorders by using neural network and comparing it with parametric and nonparametric system. In Systems, Signals and Devices, 0221. IEEE SSD 0221. 2th International Multi-Conference on (pp. 0-3). IEEE.

Rastogi, A., & Bhalla, M. (0204). A Study of Neural Network in Diagnosis of Thyroid. parameters, 4(3).

Vapnik, V. N., & Chervonenkis, A. J. (0110). The necessary and sufficient conditions for consistency of the method of empirical risk. Pattern Recognition and Image Analysis, 0(3), 084-322.

Zhang, Y., Xu, Q., Li, J. and Wang, T., 0228. A robust biased estimator for exterior orientation of pushbroom satellite imagery. Geomatica. 30, 422-433.

Zurada, J. M. (0110). Introduction to artificial neural systems (pp. 12-0008). St. Paul: West.