بسم الله الرحمن الرحيم

دانشکده کشاورزی

پایان نامه کارشناسی ارشد شیمی و حاصلخیزی خاک

برآورد گوگرد و ازت خاک در مزارع برنج استان مازندران با استفاده از مدل‌های بردار پشتیبان و شبکه عصبی مصنوعی

زینت روحی ریسه

استاد راهنما

دکترشاهین شاهسونی

استاد مشاور

دکترصمد امامقلی‌زاده

شهریور ۱۳۹۷

شماره: ۲۰۲ ک
تاریخ: ۱۳۹۷/۷/۱۶

باسمه‌تعالی

دانشگاه صنعتی شاهرود
مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای زینت روحی ریسه با شماره دانشجویی۹۴۰۸۵۱۴ رشته خاکشناسی گرایش شیمی و حاصلخیزی خاک تحت عنوان برآورد گوگرد و ازت خاک در مزارع برنج استان مازندران با استفاده از مدل های بردار پشتیبان و شبکه عصبی مصنوعی که در تاریخ ۹۷/۰۶/۱۹ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می‌گردد:

قبول (با درجه: عالی) ☐ مردود ☐

نوع تحقیق: نظری ☐ عملی ☑

عضو هیأت داوران	نام ونام خانوادگی	مرتبهٔ علمی	امضاء
۱ـ استادراهنمای اول	دکتر شاهین شاهسونی	استادیار	
۲- استادراهنمای دوم	ــــــ	ــــــ	
۳- استاد مشاور	دکتر صمد امامقلی زاده	دانشیار	
۴- نماینده تحصیلات تکمیلی	دکتر مهدی دلقندی	استادیار	
۵- استاد ممتحن اول	دکتر وجیهه درستکار	استادیار	
۶-ـ استاد ممتحن دوم	دکتر علی عباس پور	دانشیار	

نام و نام خانوادگی رئیس دانشکده: دکتر محمدرضا عامریان

تاریخ و امضاء و مهر دانشکده

تبصره: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می تواند از پایان نامه خود دفاع نماید (دفاع مجدد نباید زودتر از ۴ ماه برگزار شود).

تقدیم اثر

تقدیم به پدرم

کوهی استوار و حامی من در طول تمام زندگی

تقدیم به مادرم

سنگ صبوری که الفبای زندگی به من آموخت

تقدیم به همسرم

که در سایه همیاری و همدلی او به این منظور نائل شدم.

تشکر و قدردانی

سپاس خدایی را که همواره بزرگترین یاری گرم بوده و با لطف بی‌کرانش مسیر زندگی‌ام را روشن نموده است.

از استاد با کمالات و شایسته؛ جناب آقای دکتر شاهین شاهسونی که در کمال سعه صدر، با حسن خلق و فروتنی، از هیچ کمکی در این عرصه بر من دریغ ننمودند و زحمت راهنمایی این رساله را بر عهده گرفتند. از استاد صبور ، جناب آقای دکتر صمد امامقلی‌زاده، که زحمت مشاوره این رساله را در حالی متقبل شدند که بدون مساعدت ایشان، این پروژه به نتیجه مطلوب نمی‌رسید.

در پایان از تمام دوستانی که به نحوی اینجانب را در تدوین این مجموعه یاری نمودند صمیمانه تشکر می‌نمایم.

تعهدنامه

اینجانب زینت روحی ریسه دانشجوی دوره کارشناسی ارشد رشته مهندسی کشاورزی- خاکشناسی گرایش شیمی و حاصلخیزی خاک دانشکده کشاورزی دانشگاه صنعتی شاهرود نویسنده پایان نامه" برآورد گوگرد و ازت خاک در مزارع برنج استان مازندران با استفاده از مدل های بردار پشتیبان و شبکه عصبی مصنوعی" تحت راهنمائی آقای دکتر شاهین شاهسونی متعهد می‌شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است .
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده‌اند در مقالات مستخرج از پایان نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه‌های رایانه‌ای ، نرم افزارها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود .
- استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی‌باشد.

چکیده

خاک به عنوان یکی از عوامل اصلی در تولید محصولات کشاورزی به شمار می‌رود که استفاده از آن بایستی براساس اصول صحیح و علمی صورت پذیرد تا بتوان از آن در تولید محصولات به عنوان یک منبع پایدار یاد نمود. هرگونه اشتباه در بهره‌برداری از آن موجب از بین رفتن این منبع با ارزش می‌گردد. امروزه توسعه روش دقیق‌تر در تولید محصولات کشاورزی، یکی از راه کارها در جهت به حداقل رساندن فشار ناشی از عملیات کشاورزی بر کیفیت محیط زیست می‌باشد. در سال‌های اخیر استفاده از روش‌های مانند شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای برآورد ویژگی‌های خاک مورد توجه قرار گرفته است. لذا در این تحقیق به منظور تخمین ازت و گوگرد خاک با استفاده از مدل شبکه عصبی مصنوعی و مدل ماشین بردار پشتیبان از ویژگی‌های pH، EC، بافت و کربن آلی استفاده گردید و نتایج حاصل با هم و با مدل رگرسیون خطی چند متغیره مقایسه گردید. برای ارزیابی و تجزیه و تحلیل آماری از پارامترهای ضریب تبیین (R^2)، جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده گردید. نتایج حاصل از این تحقیق کارایی بالاتر مدل ماشین بردار پشتیبان را با (R^2 = ۰/۹۹، ۰/۹۹)، (RMSE = ۱ ، ۰/۰۰۷۴) و (MAE = ۰/۷۷۳۱۸ ، ۰/۰۰۵۷) به ترتیب برای مرحله آزمون ازت و گوگرد خاک نسبت به مدل شبکه عصبی مصنوعی نشان می‌دهد.

کلمات کلیدی: برآورد ازت، برآورد گوگرد، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، رگرسیون خطی چند متغیره.

فهرست مطالب

عنوان صفحه

فصل اول کلیات

۱- ۱- مقدمه ۲

۱- ۲- ضرورت تحقیق ۴

۱- ۳- هدف از انجام تحقیق ۴

۱- ۴- روش تحقیق ۵

فصل دوم مروری بر مطالعات گذشته

۲- ۱- مقدمه ۸

۲- ۲- بررسی عناصر غذایی اندازه‌گیری شده ۹

۲- ۲- ۱- بافت خاک ۹

۲- ۲- ۲- اسیدیته گل اشباع ۹

۲- ۲- ۳ - هدایت الکتریکی ۱۰

۲- ۲- ۴- کربن آلی ۱۱

۲- ۲- ۵ - نیتروژن ۱۲

۲- ۲- ۶- گوگرد ۱۲

۲- ۳- شبکه عصبی مصنوعی (ANN) ۱۳

۲- ۳- ۱- مدل‌سازی شبکه عصبی در ایران ۱۴

۲-۳-۲- مدل‌سازی شبکه عصبی مصنوعی در سایر کشورها ۱۷

۲- ۴- ماشین بردار پشتیبان (SVM) ۲۱

۲- ۴- ۱- الگوریتم ماشین بردار پشتیبان در ایران ۲۲

۲- ۴- ۲- الگوریتم ماشین بردار پشتیبان در سایر کشورها ۲۳

فصل سوم مواد و روش‌ها

۳- ۱- تهیه خاک برای انجام پژوهش ۲۶

۳- ۱- ۱- خصوصیات خاک ۲۶

۳- ۲- پارامترهای ورودی و خروجی به مدل‌ها (ANN و SVM و رگرسیون خطی) ۲۷
۳- ۳- اجرای شبکه پرسپترون چند لایه (MLP) ۲۷
۳- ۴- پردازش داده‌ها با استفاده از ماشین بردار پشتیبان ۲۸
۳- ۵- آشنایی با شبکه عصبی مصنوعی ۲۹
۳- ۶- تاریخچه شبکه عصبی مصنوعی ۳۰
۳- ۷- مزایای شبکه عصبی مصنوعی ۳۰
۳- ۸- توابع محرک ۳۱
۳- ۸- ۱- تابع تحریک تانژانت هیپربولیک ۳۲
۳- ۹- مراحل یادگیری ۳۳
۳- ۱۰- انواع یادگیری در شبکه عصبی مصنوعی ۳۳
۳- ۱۰- ۱- یادگیری نظارت نشده یا بدون ناظر ۳۴
۳- ۱۰- ۲- یادگیری نظارت شده یا با ناظر ۳۴
۳- ۱۱- انواع شبکه‌های عصبی مصنوعی ۳۴
۳- ۱۲- ویژگی مهم شبکه (MLP) ۳۵
۳- ۱۳- کاربردهای شبکه MLP به شرح زیر است ۳۵
۳- ۱۴- ماشین بردار پشتیبان (Support vector machines SVM) ۳۵
۳- ۱۵- کاربردهای SVM ۳۶
۳- ۱۶- مزایا و محدودیت‌های SVM ۳۷
۳- ۱۷- ابزارهای پیاده سازی SVM ۳۸
۳- ۱۷- ۱- MATLAB ۳۸
۳- ۱۷- ۲- LIBSVM ۳۸
۳- ۱۷- ۳- Svm struct matlab ۳۹
۳- ۱۸- شاخص‌های ارزیابی ۳۹

فصل چهارم بحث و نتایج

۴- ۱- مقدمه ۴۴
۴- ۲- نتایج اندازه‌گیری خصوصیات فیزیکی و شیمیایی خاک ۴۴
۴- ۲- ۱- وضعیت واکنش خاک ۴۵
۴- ۲- ۲- وضعیت شوری خاک ۴۶
۴- ۲- ۳- وضعیت درصد کربن آلی خاک ۴۶
۴- ۲- ۴- وضعیت درصد نیتروژن خاک ۴۶
۴- ۲- ۵- وضعیت گوگرد خاک ۴۷
۴- ۳- بررسی همبستگی پارامترها ۴۸
۴- ۴- بررسی تاثیر توابع انتقال در یادگیری شبکه عصبی مصنوعی ۴۹
۴- ۵- بررسی تاثیر لایه‌های پنهان در یادگیری شبکه عصبی مصنوعی ۵۱
۴- ۶- انتخاب بهترین ساختار شبکه عصبی مصنوعی ۵۳
۴- ۷- بررسی تابع کرنل RBF در SVM ۵۸
۴- ۸- اجرای مدل رگرسیون خطی چند متغییره ۶۱
۴- ۹- مقایسه مدل شبکه عصبی مصنوعی (MLP)، مدل ماشین بردار پشتیبان (SVM) و مدل رگرسیون خطی چند متغیره ۶۶

فصل پنجم نتیجه گیری و پیشنهادات

۵- ۱- نتیجه‌گیری ۷۰
۵- ۲- پیشنهادها ۷۱
منابع ۷۲
پیوست ۷۹

فهرست شکل‌ها

شکل ۳- ۱- موقعیت محدوده مورد مطالعه در Google Earth ۲۶

شکل ۳- ۲- نمایی از آموزش شبکه عصبی مصنوعی با ناظر ۲۹

شکل ۳- ۳- توابع انتقال سیگموئید، گوسین، تانژانت هایپربولیک و سکانت هایپربولیک (راهنمای نرم‌افزار Qnet)..... ۳۳

شکل ۳- ۴- نمایی از یادگیری نظارت شده یا با ناظر ۳۴

شکل ۴- ۱- مقادیر RMSE لایه‌های پنهان متفاوت برای ازت خاک ۵۲

شکل ۴- ۲- مقادیر RMSE لایه‌های پنهان متفاوت برای گوگرد خاک ۵۳

شکل ۴- ۳- نمودار پراکنش داده‌های اندازه گیری شده و پیش بینی شده برای مرحله آموزش ازت خاک مدل شبکه عصبی مصنوعی ۵۶

شکل ۴- ۴ - نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله تست در ازت خاک مدل شبکه عصبی مصنوعی ۵۶

شکل ۴- ۵ - نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش در گوگرد خاک مدل شبکه عصبی مصنوعی ۵۷

شکل ۴- ۶ - نمودار پراکنش داده های اندازه گیری شده و پیش‌بینی شده برای مرحله تست در گوگرد خاک مدل شبکه عصبی مصنوعی ۵۷

شکل۴- ۷- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل ماشین بردار پشتیبان ازت خاک ۵۹

شکل ۴- ۸- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله ارزیابی مدل ماشین بردار پشتیبان ازت خاک ۶۰

شکل۴- ۹- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل ماشین بردار پشتیبان گوگرد خاک ۶۰

شکل۴- ۱۰- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله ارزیابی مدل ماشین بردار پشتیبان گوگرد خاک ۶۱

شکل ۴- ۱۱- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون ازت خاک ۶۴
شکل ۴- ۱۲- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله تست مدل رگرسیون ازت خاک ۶۴
شکل ۴- ۱۳- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون گوگرد خاک ۶۵
شکل ۴- ۱۴- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله تست مدل رگرسیون گوگرد خاک ۶۵

فهرست جدول‌ها

جدول۲- ۱- تقسیم‌بندی خاک‌ها بر حسب تغییرات هدایت الکتریکی(برزگر۱۳۷۸) ۱۱
جدول۲- ۲- تقسیم‌بندی خاک‌ها بر اساس میزان درصد کربن آلی ۱۲
جدول۴- ۱- توصیف آماری متغیرهای فیزیکی و شیمیایی اندازه‌گیری شده خاک ۴۵
جدول ۴- ۲- همبستگی میان پارامترهای زودیافت خاک با میزان ازت خاک ۴۹
جدول ۴- ۳- همبستگی میان پارامترهای زودیافت خاک با میزان گوگرد خاک ۴۹
جدول ۴- ۴- نتایج حاصل از اجرای توابع انتقال مختلف برای تخمین ازت خاک ۵۱
جدول ۴- ۵- نتایج حاصل از اجرای توابع انتقال مختلف برای تخمین گوگرد خاک ۵۱
جدول ۴- ۶- نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین ازت و گوگرد خاک ۵۵
جدول ۴- ۷- نتایج حاصل از اجرای ماشین بردار پشتیبان برای تخمین ازت و گوگرد خاک ۵۹
جدول ۴- ۸- نتایج حاصل از اجرای مدل رگرسیونی خطی چند متغییره برای تخمین ازت و گوگرد خاک. ۶۳
جدول ۴- ۹- نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و رگرسیون خطی چند متغیره برای تخمین ازت خاک ۶۷
جدول ۴- ۱۰- نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و رگرسیون خطی چند متغیره برای تخمین گوگرد خاک ۶۷

فصل اول

کلیات

۱- ۱- مقدمه

خاک به عنوان یکی از عوامل اصلی در تولید محصولات کشاورزی به شمار می‌رود که استفاده از آن بایستی براساس اصول صحیح و علمی صورت پذیرد تا بتوان از آن در تولید محصولات به عنوان یک منبع پایدار یاد نمود. هرگونه اشتباه در بهره‌برداری از آن موجب از بین رفتن این منبع با ارز می‌گردد. بنابراین بهره‌برداری از خاک باید به گونه‌ای باشد که علیرغم رسیدن به حداکثر تولید، برای استفاده‌های بعدی نیز آسیب نبینند (دماوندی و همکاران، ۱۳۸۴).

امروزه توسعه روش دقیق تر در تولید محصولات کشاورزی، یکی از راه کارها در جهت به حداقل رساندن فشار ناشی از عملیات کشاورزی بر کیفیت محیط زیست می‌باشد.

شبکه‌های عصبی یکی از روش‌های هوشمند پردازش داده‌ها هستند که به دلیل شیوه تحلیل اطلاعات مشابه با مغز انسان، داشتن قدرت تعمیم، عدم نیاز به یک مدل ریاضی از پیش تعیین شده، عدم نیاز به نرمال بودن داده‌ها و توانایی آموزش و یادگیری می‌توانند در تخمین پارامترهای دیریافت خاک مورد استفاده قرار گیرند (محمدی، ۲۰۰۲).

با توجه به مشکلات موجود در اندازه‌گیری مستقیم برخی خصوصیات خاک، روش‌های غیر مستقیم برآورد و تخمین خصوصیات مزبور در سال‌های اخیر مورد توجه قرار گرفته‌اند. یکی از روش‌ها، ایجاد توابع انتقالی خاک است که خصوصیات دیریافت خاک را از خصوصیات زودیافت آن برآورد می‌کند (بوآما، ۱۹۸۹). در سال‌های اخیر توابع انتقالی فروانی برای تخمین خصوصیات خاک از خصوصیات فیزیکی و شیمیایی خاک ایجاد شده است (گیوی و همکاران، ۲۰۰۴). از جمله مدل‌های برآورد کننده توابع انتقالی شامل مدل های رگرسیونی (رولز و همکاران، ۱۹۹۱)، و شبکه‌های عصبی مصنوعی (میناسنی و همکاران، ۲۰۰۴) می‌باشند. شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه‌ای از

ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (تورسیلا و همکاران، ۲۰۰۴).

امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیندها در علوم مختلف بکار گرفته می‌شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها است (وکیل باغمیشه و همکاران، ۲۰۰۳).

شبکه عصبی در پیشگویی متغیرهای پیوسته ای مانند رطوبت خاک (چانگ و اسلام، ۲۰۰۰)، تخمین بیوماس(جاین و لیوو، ۱۹۹۷) و تخمین عملکرد(درومونـد و همکاران، ۲۰۰۳) نیز پتانسیل بالایی نشان داده است. مدل‌های شبکه عصبی دارای مزایایی از قبیل افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی می‌باشند.

الگوریتم ماشین بردار پشتیبان (SVM) اولیه در ۱۹۶۳ توسط ولادیمیر وپنیک ابداع شد و در سال ۱۹۹۵ توسط کورینا کورتز و وپنیک برای حالت غیرخطی تعمیم داده شد. ماشین بردار پشتیبانی (Support vector machines) یکی از روش‌های یادگیری با نظارت (learning Supervised) است که از آن برای طبقه‌بندی و رگرسیون استفاده می‌کنند. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون نشان داده است. مبنای کاری دسته بندی کننده SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. حل معادلهٔ پیدا کردن خط بهینه برای داده‌ها به وسیله روش‌های QP (Quadratic Programming) که روش‌های شناخته شده‌ای در حل مسائل محدودیت‌دار هستند صورت می‌گیرد. SVM از یک تکنیک که kernel trick نامیده می‌شود، برای تبدیل داده‌ها استفاده می‌کند و سپس بر اساس این تبدیل، مرز بهینه بین خروجی‌های ممکن را پیدا می‌کند. به

عبارت ساده تبدیلات بسیار پیچیده را انجام می‌دهد، سپس مشخص می‌کند چگونه داده‌ها را بر اساس برچسب‌ها یا خروجی‌هایی که تعریف شده، جدا کند.

۱-۲- ضرورت تحقیق

با توجه به اینکه اندازه‌گیری برخی از عناصر غذایی خاک زمان‌بر وپرهزینه بوده و همچنین نیاز به دستگاه‌های خاص و پیشرفته دارد، با توجه به این مسائل باید برای آن چاره‌ای اندیشیده شود. مدل‌های هوشمندی که امروزه از آن‌ها در تمام علوم استفاده‌های وافر می‌شود بستری را فراهم آورده است که بتوان از آن‌ها برای کاهش هزینه‌ها و صرفه‌جویی در زمان استفاده کرد. بنابراین در این تحقیق با استفاده از شبکه عصبی مصنوعی (NNA) و مدل بردار پشتیبان (SVM) به پیش‌بینی برخی خصوصیات خاک پرداخته شده است. پیش‌بینی این عناصر می‌تواند در مدیریت اراضی منطقه و مصرف بهینه کودهای شیمیایی مفید باشد.

۱-۳- هدف از انجام تحقیق

برآورد گوگرد خاک با استفاده از مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی.

برآورد ازت خاک با استفاده از مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی.

مقایسه دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی در برآورد گوگرد و ازت خاک.

مقایسه مدل رگرسیون خطی و دو مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی در برآورد گوگرد و ازت خاک.

۱-۴- روش تحقیق

این تحقیق به منظور پیش‌بینی عناصر غذایی در اراضی زراعی (برنج) در استان مازندران صورت گرفت. در این مطالعه ۱۰۰ نمونه خاک با فاصله‌های چند کیلومتر از یکدیگر از عمق ۰تا ۳۰ سانتی متر نمونه‌گیری شدند. بعد از نمونه‌برداری از بخش‌های مختلف منطقه مورد مطالعه و ضمن آماده‌سازی نمونه‌ها بر اساس استاندارد مخصوص اقدام به آنالیز برخی از ویژگی‌های شیمیایی خاک شدند. پس از آنالیز نمونه‌های خاک با استفاده از داده‌های اندازه‌گیری شده، برآورد گوگرد و نیتروژن خاک با استفاده از مدل ماشین بردار پشتیبان و شبکه عصبی مصنوعی انجام گرفت. بدین منظور از عناصر زود یافت (اسیدیته گل اشباع، کربن آلی، هدایت الکتریکی و بافت خاک) به عنوان پارامتر ورودی به مدل‌های مذکور استفاده شدند.

فصل دوم

مروری بر

مطالعات گذشته

۲-۱- مقدمه

برنج به عنوان یک غله عمده در جیره غذایی انسان دارای اهمیت است و متجاوز از ۸۰٪ جیره غذای بسیاری از کشورهای آسیایی را تامین می کند(کاباتا و پندیاس، ۱۹۸۶).

استان مازندران دارای ۲۱۸ هزار هکتارسطح زیر کشت برنج است (احمدی و همکاران، ۱۳۹۵-۱۳۹۴). اراضی شالیزاری در نواحی مختلف استان دارای وضعیت متفاوتی از نظر حاصلخیزی می‌باشند بنابراین شناخت توان خاک‌های مختلف از نظر تامین عناصر غذایی ضروری و مهم می‌باشد. شناخت این تغییرات به ویژه در اراضی کشاورزی برای برنامه ریزی دقیق و مدیریت زراعی اجتناب ناپذیر است(بوسان و کیگو، ۲۰۰۳).

با افزایش روز افزون جمعیت جهان، تقاضا برای مواد غذایی رو به فزونی نهاده است و این امر باعث افزایش فشار بر اراضی کشاورزی برای تولید مواد غذایی بیشتر شده است. در کشور ما آهکی بودن خاک‌ها، پایین بودن ماده آلی، بالا بودن شوری آب آبیاری و خاک و وجود یون کربنات و بی‌کربنات در آب آبیاری باعث شده که حاصلخیزی خاک‌ها پایین باشد و کمبود عناصر غذایی مختلف عمومیت داشته باشد. در نتیجه تغذیه گیاهان و تامین مواد غذایی کافی یکی از عوامل شیمیایی ضروری در رشد و نمو گیاهان است. از این رو راه حلی که میزان عناصر غذایی خاک را به راحتی پیش‌بینی کند و باعث کاهش هزینه و صرفه‌جویی در زمان آن گردد می‌تواند دراستفاده بجا و بهینه از کودهای شیمیایی در خاک‌هایی که با کمبود عناصر غذایی مواجه هستند کارآمد باشد. مدل‌های هوش مصنوعی مانند روش‌های شبکه عصبی و سیستم استنتاج عصبی- فازی تطبیقی به صورت موفقیت‌آمیز برای مدل‌سازی عناصر نادر خاکی در مناطق مختلف، مدل‌سازی آلودگی‌ها و پیش‌بینی پدیده‌های غیرخطی استفاده شده است(نوناری و همکاران، ۲۰۰۴).

۲-۲- بررسی عناصر غذایی اندازه‌گیری شده

پارامترهایی که در این تحقیق اندازه گیری شده و به پیش‌بینی آن‌ها با مدل‌های شبکه عصبی وماشین بردار پشتیبان پرداخته شده شامل خصوصیات فیزیکی از جمله بافت خاک، خصوصیات شیمیایی شامل اسیدیته گل اشباع، هدایت الکتریکی، کربن آلی ، ازت و گوگرد که خصوصیات آن‌ها به شرح زیر می‌باشد:

۲- ۱- بافت خاک

بافت از خصوصیت‌های مهم خاک است که از نظر مکانی متغیر و از نظر زمانی تا حدی پایدار بوده و بر بسیاری از ویژگی‌های فیزیکی و شیمیایی خاک تأثیر دارد. بافت خاک از جنبه های مختلف اهمیت بسیاری دارد(فولک ۱۹۶۶) و اهمیت آن از نظر علوم مهندسی، کشاورزی و محیط زیست به اثبات رسیده است (بایبوردی ۲۰۰۱).

بافت خاک نسبت ذرات شن، رس و سیلت در نمونه خاک است. نوع بافت خاک در ظرفیت نگهداری آب و رشد ریشه گیاهان و همچنین در پدیده آبشویی تأثیر بسزایی دارد (جعفری و سرمدیان، ۱۳۸۲).

۲-۲- اسیدیته گل اشباع

اسیدیته یا واکنش خاک (pH) در واقع بیانگر میزان اسیدیته یا قلیائیت خاک می‌باشد، به طوری که خاکی که pH کمتر از ۷ دارد اسیدی و خاکی که pH بیشتر از ۷ دارد را خاک قلیایی گویند. به طور کلی، دامنه تغییرات اسیدیته خاک در اراضی کشاورزی بین ۵ تا ۸ است. این متغیر شیمیایی را می‌توان در آزمایشگاه با تهیه عصاره گل اشباع اندازه‌گیری نمود. اهمیت واکنش خاک از آنجا ناشی می‌شود که ممکن است بر قابلیت جذب بعضی از

عناصر لازم برای رشد گیاه موثر باشد. بعضی از بیماری‌های خاکزی نیز تحت تاثیر اسیدیته خاک هستند. طبق تعریف، رابطه اسیدیته خاک عبارت است از:

$$pH = -\log (H+)$$

همان‌طور که از رابطه فوق مشخص است، در ازای تغییر هر واحد pH، غلظت یون‌های هیدروژن و هیدروکسیل، ۱۰ برابر تغییر می‌کند. شاید مهمترین اثر pH خاک بر روی رشد گیاهان، تاثیر آن در قابلیت استفاده عناصرغذایی باشد. علاوه براین، تاثیر بر فعالیت ریز جانداران خاک نیز از اثرات pH می‌باشد. تثبیت یون آمونیوم در بین شبکه کانی‌های سیلیکاتی ورقه‌ای به pH وابسته است (ملکوتی وهمکاران، ۱۳۸۷).

۲- ۳- هدایت الکتریکی

هدایت الکتریکی از مهمترین ویژگی‌های شیمیایی خاک است که به عنوان شاخص شوری در آزمایشگاه و با تهیه عصاره گل اشباع به دست می‌آید. واحد اندازه‌گیری آن دسی‌زیمنس بر متر (ds/m) یا میلی‌موس بر سانتی‌متر (mmhos/cm) می‌باشد. هدایت الکتریکی افزون بر اثر اسمزی و سمیت ویژه یونی، موجب بروز عدم تعادل تغذیه‌ای در گیاه می‌گردد که شدت و ضعف آن بسته به نوع گیاه و حتی گونه‌های مختلف یک گیاه متفاوت است. شوری خاک فعالیت یونی عناصرغذایی موجود در محلول خاک را تحت تاثیر خود قرار داده و در نتیجه توازن موجود میان نسبت آن‌ها را بر هم می‌زند (همایی، ۱۳۸۱).

یکی از مهم‌ترین اثرات صدمات شوری، کاهش رشد گیاه است. عدم توازن یونی ناشی از کاهش جذب یون‌های ضروری و انباشتگی یون‌های مضر و کمبود آب ناشی از کاهش جذب آب، منجر به کاهش سنتز پروتئین، تعرق، انتقال یون و در نهایت کاهش محصول خواهد شد (اسلام زاده و خلد برین، ۱۳۷۰).

جدول ۲-۱- تقسیم‌بندی خاک‌ها بر حسب تغییرات هدایت الکتریکی را نشان می‌دهد.

جدول۲- ۱- تقسیم بندی خاک‌ها بر حسب تغییرات هدایت الکتریکی (برزگر ۱۳۷۸)

گروه	هدایت الکتریکی(mmhos/cm)	درجه شوری	اثر شوری بر رشد ونمو گیاه
۱	۰-۲	خیلی کم	تاثیری ندارد
۲	۲- ۴	کم	اثر کمی روی گیاهان حساس دارد
۳	۴- ۸	متوسط	اثر قابل ملاحظه‌ای دارد
۴	۸-۱۶	زیاد	فقط تعداد محدودی از گیاهان می‌توانند رشد کنند
۵	بیش از ۱۶	خیلی زیاد	گیاهان فوق العاده مقاوم می‌توانند کمی رشد کنند

۲-۴- کربن آلی

نقش اساسی کربن آلی خاک در اکوسیستم‌های کشاورزی، تامین مواد غذایی و انرژی برای موجودات زنده و گیاهان خاک است(پاگیت و همکاران، ۲۰۰۱). کربن آلی نقش مهمی در خصوصیات بیولوژیکی (فراهمی اجزا و مواد غذایی مورد نیاز جمعیت میکروبی خاک)، ویژگی‌های شیمیایی(تغییرات pH و قدرت بافری خاک) و فیزیکی خاک(پایداری ساختمان خاک) داشته وتاثیر قابل توجهی روی برهم کنش‌های خاک و گیاه می‌گذارد (هوانگ و همکاران، ۲۰۰۷).

کربن آلی خاک که نماینده ماده آلی خاک است به دو بخش پایدار(دیر تجزیه شونده) و ناپایدار(زود تجزیه) تقسیم می‌شود ، بخش اول شامل کربوهیدرات‌ها، آمینواسیدها، پپتیدها، شکرهای آمینولیپیدها و کمی کند تجزیه شونده به خاطر ساختمان مانند پارافین، چربی، رزین، لیگنین، سلولوز و همی سلولوز است. بخش دوم شامل مواد هومیکی و دیگر درشت مولکول‌ها هستند که در برابر حمله میکروارگانیسم‌ها مقاومند، یا توسط سطح رس‌ها جذب شده‌اند و یا به صورت پل بین رس‌ها و خاکدانه‌ها قرار دارند(تنگ و همکاران ، ۱۹۸۹).

تقسیم بندی درصد کربن آلی خاک بر اساس استانداردهای موسسه تحقیقات خاک و آب کشور به شرح جدول (۲-۲) می‌باشد.

جدول۲-۲- تقسیم بندی خاک‌ها بر اساس میزان درصد کربن آلی

مقدار برحسب درصد	وضعیت کربن در خاک
کمتر از ۰/۵	فقیر
۰/۵ - ۱	متوسط
۱ – ۱/۵	خوب
بیش از ۱/۵	خیلی خوب

۲- ۵- نیتروژن

نیتروژن از مهمترین عناصرغذایی و یکی از عوامل کلیدی در دستیابی به عملکرد مطلوب در محصولات زراعی می‌باشد. این عنصر در گیاه بالاترین غلظت را داشته و نقش مهمی در افزایش عملکرد دارد، به طوری که کمبود آن بیش از سایر عناصر غذایی عملکرد را محدود می‌کند. مهمترین روش تامین نیتروژن مورد نیاز کشاورزی، استفاده از کودهای نیتروژنه است. برای تولیداقتصادی محصولات مختلف، حفاظت از محیط زیست، افزایش کارایی کودهای ازته و تامین نیاز غذایی جامعه، مدیریت نیتروژن از اولویت ویژه‌ای برخوردار است. بنابراین استفاده مناسب از کودهای نیتروژنه برای افزایش تولید محصول و افزایش کارایی نیتروژن، از مباحث روز می‌باشد (ملکوتی و همکاران، ۱۳۸۷).

۲- ۶- گوکرد

گوگرد پس از عناصر پرمصرف نیتروژن، فسفر و پتاسیم چهارمین عنصر عمده مورد نیاز اکثر گیاهان زراعی است(هیتسود و همکاران، ۲۰۰۵). نقش گوگرد در گیاهان، به طور عمده ساخت پروتئین و روغن و بهبود کیفیت محصولات کشاورزی است و به همین دلیل عنصر بسیار مهمی برای دانه‌های روغنی می‌باشد. در سال‌های گذشته، به دلیل آلودگی زیاد هوا ، مقدار بیشتری گوگرد از طریق اتمسفر و همچنین قارچ کش‌های حاوی گوگرد،

وارد خـاک مـی‌شـد و کمبـود آن در محصـولات کشـاورزی کمتـر مشـاهده مـی‌شـد، ولـی درسال‌های اخیر با کاهش بـاران‌هـای اسـیدزا، اسـتفاده از محصـولات پـر نیـاز بـه عناصـر غـذایی و کشاورزی متمرکز، کمبود ایـن عنصـر درمنـاطقی از جهـان تشـدید شـده اسـت و لـزوم مصـرف کودهای گوگردی را ضـروری نمـوده اسـت. گـوگرد، عنصـری حیـاتی بـرای تغذیـه گیاهـان اسـت و نقش آن برتر از فسفر می باشـد.گـوگرد، عـلاوه بـر نقـش تغذیـه ای مسـتقیم، مـی‌توانـد بـدلیل تولیـد اسـید سـولفوریک باعـث کـاهش موضـعی pH خـاک گـردد و بـه طـور غیـر مسـتقیم بـر افـزایش جـذب فسـفر و دیگـر عناصـر غـذایی کـم مصـرف مـؤثر واقـع شـود. امـروزه گـوگرد متـداولترین و اقتصـادی تـرین مـاده‌ای اسـت کـه بـرای اسـیدی کـردن خـاک بـه کـار مـی‌رود (رشیدی و کریمیان، ۱۳۷۸).

۲-۳- شبکه عصبی مصنوعی (ANN)

هـوش محاسـباتی[۱] (CI) بـه معنـای اسـتخراج هـوش، دانـش، الگـوریتم یـا نگاشـت از محاسـبات عـددی براسـاس داده‌هـای عـددی اسـت. سیسـتم CI، در اصـل سیسـتم‌هـای دینـامیکی آزاد[۲]را برای تقریب توابـع و نگاشـت‌هـا ارایـه مـی‌کننـد. مولفـه‌هـای مهـم واساسـی CI، شـبکه‌هـای عصـبی مصـنوعی (محاسـبات نرونـی)، منطـق فـازی[۳] (محاسـبات تقریبـی) و الگـوریتم ژنتیـک[۴] (محاسـبات ژنتیکـی) اسـت،که هـر یـک مغـز را بـه نـوعی الگـو قـرار داده‌انـد(منهاج و همکـاران ۱۳۸۱).

[۱] Computational Intelligence

[۲] Model Free

[۳] Fuzzy Logistic

[۴] Genetic Algorithm

۲-۳- ۱- مدل سازی شبکه عصبی در ایران

بررسی منابع نشان می‌دهد تا به حال از مدل شبکه عصبی در کارهای مختلفی مانند خاک، محیط زیست و منابع آب مورد استفاده قرار گرفته است. بازوبندی و همکاران (۱۳۹۴) به پیش بینی فلزات سنگین و CEC خاک با استفاده از خصوصیات خاک به کمک مدل‌های هوشمند پرداختند. نتایج آن کارایی بالاتر مدل شبکه‌ی عصبی مصنوعی را نسبت به روش رگرسیون خطی نشان می‌دهد. علاوه بر آن شبکه‌ی عصبی مصنوعی دارای عملکرد بهتری نسبت به شبکه‌ی عصبی فازی در مرحله‌ی تست است. اگرچه شبکه‌ی عصبی فازی در مرحله آموزش بهتر از شبکه‌ی عصبی مصنوعی عمل کرد. بازوبندی و همکاران (۱۳۹۳) به پیش بینی فسفر خاک با استفاده از خصوصیات خاک به کمک شبکه‌ی عصبی پرداختند. نتایج نشان دادکه شبکه ی پرسپترون چندلایه (MLP) به خوبی پیش بینی فسفر خاک را انجام داده است و روشی مناسب برای این پیش‌بینی میزان فسفر خاک به کمک خصوصیات خاک است.

کاشی و همکاران (۱۳۹۲) به برآورد نفوذپذیری خاک توسط شبکه عصبی مصنوعی و رگرسیون خطی در اراضی کشاورزی و بکر پرداختند. نتایج حاصل از این تحقیق کارایی بالاتر مدل شبکه عصبی مصنوعی را نسبت به روش رگرسیون خطی نشان می‌دهد. علاوه بر آن شبکه MLP دارای عملکرد بهتری نسبت به شبکهRBF در دو مرحله آموزش و تست بوده است.

قربانی و همکاران (۱۳۹۲) به ارزیابی قابلیت مدل شبکه عصبی مصنوعی LVQ4a2 در پیش‌بینی الگوی توزیع مکانی کادمیم در خاک پرداختند. نتایج به دست آمده نشان داد که شبکه عصبی آموزش دیده، دارای قابلیت بالایی در پیش‌بینی مکانی غلظت کادمیم در نقاط نمونه برداری شده با دقت تشخیص مساوی صفر درصد بود. و همچنین شبکه عصبی

مصنوعی می تواند بطور مناسبی در تشخیص سطوح مختلف غلظت کادمیم خاک بکار برده شود.

بازوبندی و همکاران (۱۳۹۶) به پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های استان گیلان با استفاده از مدل‌های هوشمند پرداختند. نتایج به‌دست‌آمده کارایی بالاتر مدل شبکه عصبی مصنوعی MLP را در مقایسه با دو مدل شبکه‌های عصبی مصنوعی از نوع RBF و مدل عصبی- فازی تطبیقی (ANFIS) مذکور با مقادیر MAE، RMSE، R^2 به ترتیب برابر با ۱/۷۹، ۲/۵۴ و ۰/۸۱ نشان داد. همچنین آنالیز حساسیت انجام‌شده بر روی داده‌های ورودی به مدل نشان داد کربن آلی بیشترین و pH کمترین همبستگی را با ظرفیت تبادل کاتیونی دارند. با توجه به نتایج این مطالعه استفاده از شبکه عصبی مصنوعی برای تخمین ظرفیت تبادل کاتیونی خاک به‌خوبی امکان‌پذیر است و می‌تواند با کارایی مناسب در جهت سهولت در اندازه‌گیری و صرفه‌جویی در زمان و هزینه‌ها به کار گرفته شود.

صمدی و همکاران (۱۳۹۲) به بررسی پهنه‌بندی عناصر غذایی با استفاده از شبکه عصبی مصنوعی و زمین آمار در دشت ارومیه پرداختند. نتایج این پژوهش نشان داد که شبکه عصبی مصنوعی می‌تواند بر اساس خطای کم تشخیص در فاز آموزش و آزمایش در تهیه نقشه پهنه‌بندی غظت عناصر و ویژگی‌های خاک بکار برده شود.

علیجانپورشلمانی و همکاران (۱۳۹۰) به تخمین پایداری خاکدانه در خاک‌های جنگلی استان گیلان بوسیله شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی پرداختند. بر اساس آماره‌های ضریب تبیین تصحیح شده(R^2) ، ریشه دوم میانگین مربعات خطا (RMSE) و برتری نسبی (RI) مدل با متغیرهای ورودی pH، چگالی حقیقی، سیلت و مقاومت مکانیکی خاک بهترین مدل شبکه عصبی مصنوعی برای برآورد GMD داده‌های مورد آزمایش شناخته شد.

معماریان فرد و بیگی هرچگانی (۱۳۸۸) به مقایسه توابع انتقالی رگرسیونی و شبکه عصبی مصنوعی برای پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های استان چهارمحال و بختیاری پرداختند. در این مطالعه، توابع انتقالی برای پیش‌بینیCEC، از خصوصیات اساسی ۲۰۰ خاک مانند توزیع اندازه ذرات، کربن آلی، درصد رطوبت اشباع و pH توسعه داده شد. نتایج نشان داد هنگامی که از شبکه عصبی با یک لایه پنهان و هفت نرون در این لایه و ماده آلی، درصد رطوبت اشباع، درصد رس و شن به عنوان ورودی استفاده شد، CEC با۸۱٪ = R^2 و۰/۰۵۳= RMSE بهتر از دیگر مدل‌ها پیش‌بینی شد. محمدرضا پهلوان راد و همکاران (۱۳۹۴) به منظور مقایسه روش‌های زمین آماری و شبکه عصبی مصنوعی در تخمین رس خاک، در بخشی از اراضی شهرستان زهک سیستان تحقیقی انجام دادند. تعداد ۱۲۱ نمونه خاک با فواصل ۷۵۰ متر از عمق۳۰ - ۰ سانتیمتر برداشت و مقادیر رس خاک تعیین شد. از این تعداد ۱۰۵ نمونه برای آموزش مدل‌ها و ۱۶ نمونه جهت اعتبار سنجی مدل‌ها استفاده شد. مدل‌های مختلف زمین آماری و شبکه عصبی مصنوعی برازش و بهترین مدل‌ها انتخاب شدند. مقایسه دو روش نشان داد که شبکه عصبی با ضریب تبیین ۶۸٪ و با معیار خطای ۱۸/۶در مقایسه با روش زمین آمار با ضریب تبیین۶۲٪ و با معیار خطای ۲/۸ مقدار رس خاک را بهتر پیش‌بینی می‌کند.

موسوی زاده مجرد و سپاسخواه (۱۳۸۷) از مدل شبکه عصبی مصنوعی برای پیش‌بینی منحنی مشخصه آب خاک استفاده کردند. نتایج آن‌ها حاکی از کارایی بالاتر الگوریتم تنظیم بایسن نسبت به الگوریتم لونبرگ-مارکوئت بود. مهربانیان و همکاران، (۱۳۸۹) از مدل شبکه عصبی برای تخمین ظرفیت تبادل کاتیونی خاک‌های آهکی و گچی استان یزد استفاده کردند و با اندازه گیری پارامترهای اجزا بافت خاک و درصد کربن آلی خاک به پیش‌بینی ظرفیت تبادل کاتیونی با مدل‌های شبکه عصبی و رگرسیون خطی پرداختند. نتایج آن‌ها

کارایی بالای شبکه عصبی را که دارای روابط غیر خطی میان متغییرهای وابسته پیش‌بینی شونده می‌باشد را در مقایسه با روابط رگرسیونی به خوبی نشان داد.

خداوردی لو و همکاران (۱۳۸۳) در تحقیقی با اندازه‌گیری منحنی رطوبتی خاک، فراوانی نسبی ذرات خاک، وزن مخصوص ظاهری و درصد کربنات کلسیم معادل به تخمین هوشمند منحنی رطوبتی خاک با استفاده از شبکه عصبی مصنوعی پرداختند و به انطباق معنی دار در سطح احتمال یک درصد بین منحنی رطوبتی پیش‌بینی شده و اندازه‌گیری شده دست یافتند. همچنین نتایج کارایی بالاتر شبکه عصبی مصنوعی نسبت به توابع انتقالی رگرسیونی را نشان داد. دعایی و همکاران (۱۳۸۴) در ۲۲ نمونه خاک رسی استان گیلان با استفاده از پارامترهای فیزیکی درصدرس، کربن آلی و وزن مخصوص ظاهری به عنوان پارامترهای زود یافت و نیز مقدار ضریب آبگذری اشباع به عنوان یک پارامتر دیر یافت خاک استفاده کردند و نتایج نشان داد که شبکه عصبی بهترین و دقیق ترین تخمین را در مدل‌سازی ضریب آبگذری اشباع نشان می‌دهد.

۲-۳- ۲- مدل سازی شبکه عصبی مصنوعی در سایر کشورها

اریکو و همکاران (۲۰۰۸) در تحقیقی به پیش‌بینی ساده پتانسیل نیتریفیسیون خالص(NNP) خاک‌های جنگلی ژاپن با شبکه عصبی مصنوعی پرداختند. این مطالعه با هدف توسعه یک مدل شبکه عصبی مصنوعی برای پیش‌بینی NNP که نیاز به چندین خواص خاک برای داده‌های ورودی است، انجام شد.پیش‌بینی NNP با استفاده از تعداد کمی از خواص خاک یک ابزار مفید برای برنامه ریزی مدیریت جنگل است. مدل مبتنی بر ANN با استفاده از داده‌ها فقط بر روی دو خواص خاک (نسبت C: N و حداکثر ظرفیت نگهداری آب) بهترین پیش‌بینی NNP را فراهم کرد. این سادگی مدل، ارزش عملی خود را در برنامه ریزی مدیریت جنگل افزایش می‌دهد .

رامش و همکاران (۲۰۱۱) در تحقیقی به بررسی پیش‌بینی نیترات باقی مانده خاک از اطلاعات شبیه سازی و غیر شبیه سازی با استفاده از روش شبکه عصبی پرداختند. از اطلاعات غیرتصویری ماهواره LANDSAT ویژگی‌های متنی استخراج شده از تصاویر ماهواره‌ای مانند هدایت الکتریکی خاک، عملکرد محصول، توپوگرافی و مواد باقیمانده خشک محصول و غیره به منظور توسعه مدل‌های پیش‌بینی نیترات باقی مانده در خاک به کمک سه مدل شبکه‌های عصبی پس انتشار، مدولار(وابسته به قدر مطلق)، و عملکرد پایه شعاعی ساختاری استفاده شد. پارامترهای آماری برای ارزیابی عملکرد سه مدل شبکه عصبی مقایسه شدند. پیش‌بینی نیترات باقیمانده خاک بر اساس مدل شبکه‌های عصبی پس انتشار (BPNN) بالاترین میزان متوسط دقت را به ترتیب ۸۳/۲۹ درصد و پایین ترین میانگین مربع خطای ۱۰/۶۱درصد را نشان می‌دهد. ضریب همبستگی ۹۱ درصد بالاترین مقداری بود که توسط تمام سه مدل شبکه عصبی ارائه شده است. آنالیز حساسیت نشان دهنده اهمیت برابر هر دو تصویر و متغیرهای غیر تصویری برای پیش‌بینی محتوای نیترات باقی مانده خاک در شرایط مزرعه است.

شارما و همکاران (۲۰۰۳) در تحقیقی به بررسی شبکه‌های عصبی برای پیش‌بینی نیترات - نیتروژن در آب زهکشی پرداختند دو مدل شبکه عصبی مصنوعی(ANN) ، یک شبکه سریع پس انتشار (FBP) و یک شبکه تابع پایه شعاعی خودسازمانده (RBF) ، برای شبیه سازی توسعه داده شد. داده‌های موجود در زمینه‌های آموزشی و تست که با آن‌ها تدوین شده بود، تقسیم شدند فایل آموزش شامل هشت ورودی و دو خروجی است. آنالیز حساسیت توسط تغییر پارامترهای شبکه برای به حداقل رساندن خطای پیش‌بینی و تعیین شبکه مطلوب انجام شد. که بهترین مدل FBP شامل ۲۰ نورون در لایه پنهان است و یک نرخ یادگیری از ۰/۰۲، در حالی که شبکه RBF ۵۴۷ نورون در لایه پنهان به دست آورد. به طور کلی، عملکرد شبکه عصبی RBF در مقایسه با مدل FBP در پیش‌بینی غلظت نیترات-

نیتروژن در جریان خروجی تخلیه به دلیل استفاده از کود بیشتر است. این اطلاعات به نوبه خود می‌تواند برای مدیریت کود مناسب مورد استفاده قرار گیرد در نتیجه، نه تنها از دست دادن کود نیتروژن ارزشمند، بلکه پتانسیل برای آلودگی آب‌های زیر سطحی توسط نیترات کاهش یافت .

شافی و همکاران (۲۰۱۴) در تحقیقی به حذف تداخل رطوبت خاک و اندازه ذرات در پیش‌بینی محتوای کل نیتروژن خاک با استفاده از یک آشکارساز قابل حمل مبتنی بر NIRS پرداختند. استفاده از طیف سنجی نزدیک بازتاب مادون قرمز (NIRS) در مزارع به طور موثر می‌تواند نیتروژن کل (TN) محتوای خاک را همزمان برآورد کند. آن‌ها یک آشکارساز قابل حمل مبتنی بر NIRS از محتوای TN خورشیدی که داده‌های طیفی را در ۹۴۰، ۱۰۵۰، ۱۱۰۰، ۱۲۰۰، ۱۳۰۰، ۱۴۵۰ و ۱۵۵۰ نانومتر اندازه‌گیری می‌کرد، توسعه دادند. دخالت این عوامل در پیش‌بینی محتوای خاک TN باید با استفاده از آشکارساز قابل حمل حذف شود. ابتدا نمونه‌های خاک از یک مزرعه در پکن، چین، و با استفاده از آشکارساز اسکن شدند تا داده‌های جذب خود را با توجه به رطوبت و اندازه ذرات مختلف، بدست آورند. دوم، روش تصحیح جذب و روش کالیبراسیون مخلوط به منظور اصلاح داده‌های طیفی اصلی و حذف تداخل رطوبت خاک و اندازه ذرات پیشنهاد شد. جذب نمونه خاک در ۱۴۵۰ نانومتر، با رطوبت خاک همبستگی بالایی داشت. بنابراین، روش تصحیح جذب رطوبت (PMAI) برای به حداقل رساندن داده‌های طیفی اصلی به داده‌های طیفی استاندارد پیشنهاد شده و در نتیجه تداخل رطوبت خاک را از بین می‌برد. یک کالیبراسیون مخلوط مبتنی بر NIRS مبتنی بر افزودنی‌های طیف NIR با اندازه‌های مختلف ذرات، جدا شده از نمونه‌های اولیه خاک، برای از بین بردن دخالت اندازه ذرات خاک بر روی اندازه گیری دستگاه TN قابل حمل خاک تولید می‌شود. مدل تخمینی محتوای TN بر اساس داده‌های جذب شده تصحیح شده در شش طول موج (۹۴۰، ۱۰۵۰، ۱۱۰۰، ۱۲۰۰، ۱۳۰۰

و ۱۵۵۰ نـانومتر) بـا اسـتفاده از الگـوریتم شـبکه عصـبی انتشـار پیشـرفته ایجـاد شـد. ضـریب همبسـتگی کالیبراسـیون، ضـریب همبسـتگی اعتبارسـنجی، خطـای متوسـط مربعـات خطـا کالیبراسـیون، میـانگین خطـای مربـع پـیش‌بینـی و انحـراف پـیش‌بینـی هـای بـاقی مانـده بـرای ارزیـابی مـدل مـورد اسـتفاده قـرار گرفـت. در مقایسـه بـا مـدل اسـتفاده شـده از داده‌هـای طیفـی اصلی، دقت و پایداری مدل جدید بـه طـور قابـل تـوجهی بهبـود یافـت. ایـن روش‌هـا مـی‌تواننـد بـه طـور مـوثر از تـداخل رطوبـت خـاک و انـدازه ذرات در پـیش‌بینـی محتـوای TN خـاک جلـوگیری کنند.

اخمـاج (۲۰۱۰) بـا اسـتفاده از پارامترهـایی شـامل رس، شـن، سـیلت، وزن مخصـوص ظـاهری، هـدایت هیـدرولیکی اشـباع و حجـم آب در خـاک بـه پـیش‌بینـی میـزان نفوذپـذیری خـاک توسـط مـدل شـبکه عصـبی مصـنوعی و مـدل رگرسـیون خطـی پرداخـت. نتـایج او نشـان دهنده کارایی بالاتر مدل شبکه عصبی نسبت به رگرسیون خطی می باشد.

تامـاری و همکـاران (۱۹۹۶) در مطالعـه‌ای نشـان دادنـد کـه اگـر ناپایـداری داده‌هـا بـالا باشـد، شبکه عصبی از مدل هـای رگرسـیون خطـی بهتـر نخواهـد بـود، امـا زمـانی کـه داده‌هـایی بـا دقـت بالا به کـار بـرده شـود شـبکه عصـبی کـارایی بـالاتری را نشـان مـی‌دهـد . راب و همکـاران (۲۰۰۹) در تحقیقـی از شـبکه‌هـای MLP و RBF بـرای بـرآورد شـاخص‌هـای ناهمـاهنگی خـاک اسـتفاده کردند که طبق بررسی آن‌ها، شبکه MLP از کارایی بالاتری برخوردار بود.

در مطالعـه‌ای کـه توسـط مـردان و همکـاران (۲۰۰۶) انجـام شـد، توابـع انتقـالی بـرای نقـاط FC و PWP بـا اسـتفاده از توزیـع انـدازه ذرات و جـرم مخصـوص ظـاهری توسـط شـبکه عصـبی و رگرسیون چند متغیره ی خطـی بـه دسـت آمـد و کـارایی ایـن روش‌هـا بـا نتـایج انـدازه‌گیـری‌هـای مستقیم مقایسـه گردیـد. بـرای دانسـتن میـزان اعتبـار توابـع انتقـالی خـاک، ۱۹۵ نمونـه خـاک بـه دو گـروه تقسـیم شـد، یـک گـروه شـامل ۱۳۰ نمونـه و گـروه دیگـر شـامل ۶۵ نمونـه خـاک بـود. اگرچـه تفـاوت نتـایج بـین دو روش در سـطح ۵٪ معنـی‌دار نبـود، ولـی رگرسـیون چنـد متغیـره

خطـی تخمـین بهتـری ارائـه داد و هـر دو روش در تعـداد نمونـه بیشـتر، دقـت بـالاتری را نشـان دادند.

مینسـانی و مکبراتنـی (۲۰۰۲) بـرای بـرآورد پارامترهـای مـدل ون گنخـتن در خـاک‌هـای اسـترالیا از شـبکه عصـبی مصـنوعی اسـتفاده شـد. ایـن پژوهشـگران در طراحـی شـبکه عصـبی مصنوعی تابع هدف جدیدی ارایـه نمودنـد. در ایـن پـژوهش بـه جـای اینکـه تـابع هـدف مـورد نظـر را بـا اسـتفاده از پارامترهـای ون گنخـتن تعیـین کننـد، از مقـدار رطوبـت بـرآورد شـده از مـدل ون گنخـتن اسـتفاده نمودنـد. نتـایج ایـن پـژوهش نشـان داد کـه تـابع هـدف ارائـه شـده اثـری قابـل قبول در بهبود عملکرد شبکه داشته است.

۲-۴- ماشین بردار پشتیبان (SVM)

ماشـین بـردار پشـتیبانی (Support vector machines) یکـی از روش‌هـای یـادگیری بانظـارت (learning Supervised) اسـت کـه از آن بـرای طبقـه‌بنـدی و رگرسـیون اسـتفاده مـی‌کننـد (بسـالت پـور و همکـاران، ۱۳۹۴). ایـن روش از جملـه روش‌هـای بـه نسـبت جدیـدی است که در سال‌های اخیـر کـارایی خـوبی نسـبت بـه روش‌هـای قـدیمی تـر طبقـه‌بنـدی، از جملـه شـبکه‌هـای عصـبی مصـنوعی نشـان داده اسـت(وپنیـک، ۱۹۹۵). مبنـای کـاری دسـته‌بنـدی کننده‌یSVM دسته‌بندی خطـی داده‌هـا اسـت و در تقسـیم خطـی داده‌هـا سـعی مـی‌کنـیم خطـی را انتخاب کنیم که حاشـیه اطمینـان بیشـتری داشـته باشـد. حـل معادلـۀ پیـدا کـردن خـط بهینـه بـرای داده‌هـا بـه وسـیله روش‌هـای QP (Quadratic Programming) کـه روش‌هـای شـناخته شـده‌ای در حـل مسـائل محـدودیت‌دار هسـتند صـورت مـی‌گیـرد. SVM از یـک تکنیـک کـه kernel trick نامیـده مـی‌شـود، بـرای تبـدیل داده‌هـا اسـتفاده مـی‌کنـد و سـپس بـر اسـاس ایـن تبدیل، مـرز بهینـه بـین خروجـی‌هـای ممکـن را پیـدا مـی‌کنـد. بـه عبـارت سـاده تبـدیلات بسـیار

پیچیده را انجام می‌دهد، سپس مشخص می‌کند چگونه داده‌ها را بر اساس برچسب‌ها یا خروجی‌هایی که تعریف شده، جدا کند.

۲-۴- ۱- الگوریتم ماشین بردار پشتیبان در ایران

نظریات و همکاران (۱۳۹۴) به بررسی توزیع غلظت سرب با استفاده از ماشین بردار پشتیبان در خاک سطحی زمین‌های حاشیه بزرگراه دزفول - اهواز پرداختند. بر اساس نتایج این پژوهش به نظر می‌رسد بتوان از ماشین‌های بردار پشتیبان برای تعیین عوامل مؤثر بر دریافت سرب در خاک حاشیه جاده‌ها و مدل‌سازی تغییرات غلظت آن در خاک استفاده نمود.

بسالت پور و همکاران (۱۳۹۳) از روش غیرخطی ماشین‌های بردار پشتیبان (SVMs) برای بررسی اثرات برخی از ویژگی‌های توپوگرافی، فیزیکی و مکانیکی خاک بر فرسایش‌پذیری در بخشی از حوزه‌ی آبخیز کارون شمالی واقع در غرب استان چهارمحال و بختیاری استفاده و نتایج حاصله با خروجی حاصل از روش خطی رگرسیون چند متغیره (MLR) مقایسه شد. همچنین قابلیت استفاده از این دو روش برای برآورد فاکتور فرسایش‌پذیری خاک در منطقه‌ی مورد مطالعه، بررسی گردید. نتایج نشان داد که مدل غیرخطی SVMs دارای کارایی بسیار بالاتری نسبت به روش خطی مرسوم (رگرسیون چند متغیره) برای تخمین فاکتور فرسایش‌پذیری بود.

مدل SVM با استفاده از مساله بهینه‌سازی دو گانه برای پیش‌بینی رواناب روزانه از رودخانه بختیاری با استفاده از داده‌های هواشناسی و بارندگی استفاده گردید و نتایج آن با مدل ANN وشبکه- الگوریتم ژنتیک (ANN-GA) مقایسه شد. روش SVM منجر به مقادیر RMSE کمتری نسبت به دو روش دیگر داشت و روشی سریعترو با دقت بالاتر بود(بهزاد و همکاران، ۲۰۰۹). در زمینه تبخیر - تعرق نیز توانایی SVM در اصلاح دقت

برآورد تبخیر روزانه در مخازن چاه نیمه زابل مورد بررسی قرار گرفت(مقدم نیا و همکاران، ۲۰۰۸).

شهبازی و همکاران (۲۰۱۲) مطالعه‌های در زمینه پیش‌بینی فصلی خشکسالی درحوزه سدهای طالقان و ماملو با مدل ماشین بردار پشتیبان انجام دادند. ماشین بردار پشتیبان برای پیش‌بینی نمایه بارش استاندارد (SPI)[1] استفاده گردید که نتایج حاصل در اکثر موارد دقت خوبی را نشان داد.

طاهری و همکاران (۲۰۱۲) دو روش یادگیری فعال[2] و ماشین بردار پشتیبان را برای شبیه سازی جریانات روزانه رودخانه کارون مورد مقایسه قرار دادند و قابلیت بالای ماشین بردار پشتیبان در شبیه سازی رواناب را مطرح نمودند.

۲- ۴- ۲- الگوریتم ماشین بردار پشتیبان در سایر کشورها

میسترا و همکاران (۲۰۰۹) با مقایسه مدل ماشین بردار پشتیبان با شبکه عصبی مصنوعی به پیش بینی رواناب و بار رسوب با استفاده از داده‌های روزانه، هفتگی و ماهانه در حوزه آبخیز هند پرداختند. نتایج نشان داد ماشین بردار پشتیبان هم در زمینه پیش‌بینی رواناب و هم بار رسوب نسبت به شبکه عصبی مصنوعی بهتر می‌باشد.

یون و همکاران (۲۰۱۱) دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان را به منظور پیش‌بینی تغییرات سطح آب زیرزمینی استفاده کردند، که نتیجه این تحقیق حاکی از برتری مدل ماشین بردار پشتیبان می‌باشد .

بوتسیس و همکاران (۲۰۱۱) بارش-رواناب روزانه در کالیفرنیا را شبیه‌سازی کردند، مدل ماشین بردار پشتیبان با سه نوع تابع کرنل با مدل شبکه عصبی مصنوعی مورد مقایسه

[1] Standard Precipitation Index
[2] Active Learning Metho

قـرار گرفـت، در نتیجـه ایـن تحقیـق ماشـین بـردار پشـتیبان شـبیه سـازی دقیـق‌تـری از بـارش رواناب داشت .

فصل سوم

مواد و روش‌ها

۳-۱- تهیه خاک برای انجام پژوهش

در این مطالعه، خاک مورد نیاز از اراضی زراعی (برنج) از استان مازندران واقع در شمال ایران تهیه شد. ۱۰۰نقطه در اراضی زراعی با فاصله‌های چند کیلومتر از یکدیگر انتخاب شدند. نقاط مورد مطالعه خاک از عمق ۳۰-۰ سانتی‌متری سطح خاک جمع‌آوری شد.

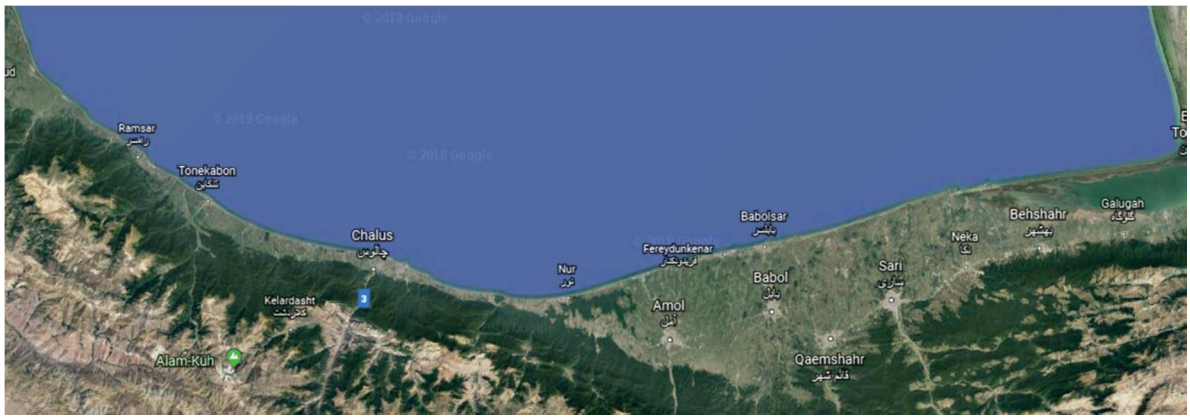

شکل ۳- ۱- موقعیت محدوده مورد مطالعه در Google Earth

۳-۱- ۱- خصوصیات خاک

پس از جمع‌آوری خاک‌ها و هوا خشک شدن از الک ۲ میلی‌متری عبور داده شد تا مخلوط یکنواختی حاصل گردد. مطالعات خاکشناسی شامل pH و EC آن‌ها پس از تهیه عصاره گل اشباع با دستگاه pH متر(توماس، ۱۹۹۶) و دستگاه هدایت سنج(رودس، ۱۹۹۶) ، بافت خاک به روش هیدرومتری(بیوکس، ۱۹۶۲) ، کربن آلی به روش والکلی بلاک[1] (۱۹۳۴)، گوگرد (با روش استات آمونیم، اسید استیک و کلرور باریم با اسپکروفتومتر) و نیتروژن به روش کجلدال(برمنر و مولوینی، ۱۹۷۸) در آزمایشگاه انجام شد.

[1] Walkley Black

۳- ۲ - پارامتر هـای ورودی و خروجـی بـه مـدل‌هـا (ANN وSVM و رگرسـیون خطی)

پارامترهـای اسـتفاده شـده شـامل مقـادیر pH، EC، بافـت و کـربن آلـی بـه عنـوان داده‌هـای ورودی بـه مـدل‌هـا و ازت و گـوگرد خـاک بـه عنـوان پارامترهـای خروجـی در نظـر گرفتـه شـد و ۸۰ درصـد داده‌هـای ورودی بـرای قسـمت آمـوزش و ۲۰ درصـد بـرای قسـمت تسـت اختصـاص داده شـدند. در هـر سـه مـدل مـورد اسـتفاده بـرای عناصـر دیریافـت خـاک، پارامترهـای ورودی بـه سیستم، شامل پارامترهای زودیافت مذکور بودند.

۳-۳- اجرای شبکه پرسپترون چندلایه (MLP)

بـرای بررسـی نرمـال بـودن داده‌هـا مـی‌تـوان از ضـریب چـولگی و ضـریب کشـیدگی داده‌هـا اسـتفاده نمـود. اگـر ضـریب چـولگی بـین مقـادیر ۲+ و ۲- و ضـریب کشـیدگی بـین مقـادیر ۳+ و ۳- باشد، داده‌ها نرمال بوده و نیازی به نرمال‌سازی نمی‌باشد(جورج و مالری، ۲۰۱۰).

بـرای اجـرای مـدل، داده‌هـا بـه صـورت ۸۰٪ و ۲۰٪ بـه ترتیـب بـرای مرحلـه آمـوزش و تسـت تفکیـک شـدند. از آنجاییکـه در یـادگیری شـبکه عصـبی مصـنوعی تعـداد لایـه‌هـای میـانی و نـوع توابع انتقالی تاثیر مهمـی بـر فرآینـد یـادگیری شـبکه‌هـای عصـبی مصـنوعی دارنـد در بخـش‌هـای زیـر تـاثیر آن‌هـا بـه طـور جداگانـه مـورد بررسـی قـرار گرفـت و سـپس بهتـرین سـاختار شـبکه عصبی مصنوعی انتخاب گردید.

در ساخت یک مـدل بـر مبنـای شـبکه عصـبی، اولـین کـار انتخـاب نـوع شـبکه اسـت. در ایـن تحقیق شـبکه عصـبی بـا سـاختار پرسـپترون چندلایـه (MLP) مـورد اسـتفاده قـرار گرفتـه اسـت و دلیل این انتخـاب توانـایی ایـن نـوع شـبکه‌هـا بـرای دسـته‌بنـدی (Classification) و کلاسـه‌بنـدی (Clustring) و یافتن نگاشته‌های نامعلوم می‌باشد.

در این شبکه تعداد نرون‌های لایه‌های ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرون‌های لایه خروجی برابر با تعداد عناصر بردار خروجی می‌باشد. ولایه یا لایه‌های پنهان وظیفه ارتباط لایه‌های ورودی به لایه‌های خروجی و به دست آوردن روابط خطی و غیر خطی را بر عهده دارند(میناسی و مک برانتنی، ۱۹۹۹).

۳-۴- پردازش داده‌ها با استفاده از ماشین بردار پشتیبان

تقسیم‌بندی داده‌ها در این قسمت مشابه تقسیم‌بندی برای مدل‌های شبکه عصبی مصنوعی صورت گرفته است. به این ترتیب که ۸۰٪ داده‌ها برای آموزش ماشین بردار پشتیبان و ۲۰٪ داده‌ها برای تست استفاده شده‌اند. برای پردازش داده‌ها از روش ماشین بردار پشتیبان از نرم افزار MATLAB استفاده شد. در این روش از تابع کرنل RBF استفاده شد.

در مدل‌سازی باید نکات زیر را مدنظر داشت:

۱- معمولا تعداد داده‌های بیشتری در مجموعه آموزش قرار گیرند تا مدل ما تعمیم و کارایی بیشتری بر روی داده‌های آموزش خواهد داشت.

۲- بایستی بین داده‌های آموزش و تست دارای ویژگی‌های آماری مشابه (میانگین و انحراف معیار و ..) و همبستگی آماری بوده تا مدل قابلیت تعمیم و اطمینان مناسب را داشته باشد. در واقع یکی از حساسیت‌های روش ماشین بردار پشتیبان یا هوش مصنوعی عدم دسته بندی مناسب داده‌های آموزش و تست می‌باشد.

۳- معمولا تعداد اندکی از داده‌ها را برای ارزیابی در نظر می‌گیرند از خصوصیات اصلی این داده‌ها صحت پارامترهای ورودی و خروجی این داده‌ها بوده که معمولا برای ارزیابی صحت مدل استفاده می‌گردد.

۳- ۵- آشنایی با شبکه عصبی مصنوعی

شبکه‌های عصبی از عناصر عملیاتی ساده‌ای ساخته می‌شوند که به صورت موازی کنار هم عمل می‌کنند. این عناصر از سیستم‌های عصبی زیستی الهام گرفته شده‌اند. در طبیعت، عملکرد شبکه‌های عصبی از طریق نحوه اتصال بین اجزا تعیین می‌شود. بنابراین ما می‌توانیم یک ساختار مصنوعی به تبعیت از شبکه‌های طبیعی بسازیم و با تنظیم مقدار هر اتصال، تحت عنوان وزن اتصال، نحوه ارتباط بین اجزای آن را تعیین نماییم (کیا، ۱۳۸۹).

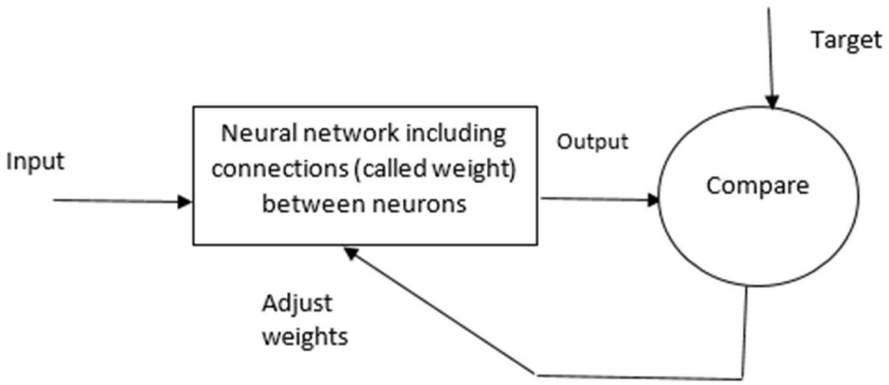

شکل ۳- ۲- نمایی از آموزش شبکه عصبی مصنوعی با ناظر

پس از تنظیم یا همان آموزش شبکه عصبی ، اعمال یک ورودی خاص به آن منجر به دریافت پاسخ خاصی می‌شود. همان طور که در شکل (۳-۲) نمایش داده شده‌است شبکه برمبنای تطابق و همسنجی بین ورودی و هدف سازگار می‌شود تا اینکه خروجی شبکه و خروجی مورد نظر ما (هدف) برهم منطبق گردند. عموما تعداد زیادی از این زوج‌های ورودی و خروجی به کار گرفته می‌شوند تا در این روند که در آن تحت عنوان یادگیری نظارت شده یاد می‌شود شبکه آموزش داده شود. امروزه از شبکه‌های عصبی برای حل مسائل دشواری که حل آن‌ها با روش‌های معمولی دشوار می‌باشد استفاده می‌کنند.

۳-۶- تاریخچه شبکه عصبی مصنوعی

از قرن نوزدهم به طور همزمان اما جداگانه از سویی نروفیزیولوژیست‌ها سعی کردند سیستم یادگیری و تجزیه و تحلیل مغز را کشف کنند و از سوی دیگر ریاضیدانان تلاش کردند تا مدل ریاضی بسازند، که قابلیت فراگیری و تجزیه و تحلیل عمومی مسائل را دارا باشد. سال ۱۹۶۹ مدل Mp شبکه مصنوعی توسط مک کالوخ و پیت مطرح شد که یک مدل خطی ساده بود، سپس پروسپترون الگوریتم یادگیری را ارائه نمود (منهاج، ۱۳۸۱). سال ۱۹۶۹ آغاز افول موقت شبکه عصبی شد، زیرا عدم توانایی شبکه عصبی در حل مسائل غیرخطی آشکار شد. شبکه‌های عصبی مصنوعی آن زمان فقط قادر به حل مسائلی بودند که می‌شد پاسخ‌های آن مساله را توسط یک خط در محور مختصات از هم جدا کرد. در سال ۱۹۸۲ هاپفیلد با معرفی شبکه‌های چند لایه و الگوریتم‌های یادگیری دارای بازخورد راه حلی برای حل موارد غیر خطی ارائه کرد. در این زمان بود که شبکه‌های بازگشتی، خود سازنده (Radial basis function) BF، Autoregressive و... با توجه به این پیشرفت‌های انجام شده در زمینه شبکه عصبی مصنوعی نرم افزارهای زیادی در این زمینه نوشته شده که می توان به نرم افزارهای Qnet2000، Nero solution ، Neuralworks و جعبه افزار شبکه مصنوعی در Matlab اشاره نمود.

۳- ۷- مزایای شبکه عصبی مصنوعی

شبکه‌های مصنوعی با توانایی قابل توجه در استنتاج نتایج از داده‌های پیچیده می‌تواند در استخراج الگوها و شناسایی گرایش‌های مختلفی که برای انسان‌ها و کامپیوتر شناسایی آن‌ها بسیار دشوار است استفاده شوند. از مزایای شبکه عصبی می‌توان موارد زیر را نام برد:

۱. یادگیری تطبیقی : توانایی یادگیری اینکه چگونه وظایف خود را براساس اطلاعات داده شده به آن و یا تجارب اولیه انجام دهد در واقع اصلاح شبکه را گویند.

۲. خود سازماندهی: یک شبکه مصنوعی به صورت خودکار سازماندهی و ارائه داده‌هایی که در طول آموزش دریافت کرده را انجام دهد. نرون‌ها با قاعده یادگیری سازگار شده و پاسخ به ورودی تغییر می‌یابد.

۳. عملکردهای بی درنگ: محاسبات در شبکه عصبی مصنوعی می‌تواند به صورت موازی و به وسیله سخت افزارهای مخصوصی که طراحی و ساخت آن برای دریافت نتایج بهینه قابلیت‌های شبکه عصبی مصنوعی است انجام شود.

۴. تحمل خطا : با ایجاد خرابی در شبکه مقداری از کارایی کاهش می‌یابد ولی برخی امکانات آن با وجود مشکلات بزرگ همچنان حفظ می‌شود.

۵. دسته‌بندی: شبکه‌های عصبی قادر به دسته‌بندی ورودی‌ها برای دریافت خروجی مناسب می‌باشند.

۶. تعمیم‌دهی: این خاصیت شبکه را قادر می‌سازند تا تنها با برخورد با تعداد محدودی نمونه، یک قانون کلی از آن را به دست آورده، نتایج این آموخته‌ها را به موارد مشاهده از قبل نیز تعمیم دهد.

۷. پایداری- انعطاف‌پذیری: یک شبکه عصبی هم به حد کافی پایدار است تا اطلاعات فراگرفته خود را حفظ کند و هم قابلیت انعطاف و تطبیق را دارد و بدون از دست دادن اطلاعات قبلی می‌تواند موارد جدید را بپذیرد.

۳- ۸- توابع محرک

نرون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند. نرم افزار Qnet 2000 که به منظور مدل‌سازی در این پروژه استفاده گردید دارای چهار تابع انتقال سیگموئید، گوسین ، تانژانت هایپربولیک و سکانت هایپربولیک بوده که از این بین تابع سیگموئید ، تابع پیش فرض می‌باشد و بطور وسیعی در شبکه‌های عصبی انتشار برگشتی

کاربرد دارد. این تابع نیز مقادیر ورودی را بین صفر و یک محدود می‌کند با این تفاوت که میزان تغییرات آن غیر خطی است. مزیت این تابع در عملکرد آن با ورودی‌های بزرگ و یا کوچک است. هنگامی که مقادیر ورودی به سمت اعداد منفی بزرگ میل کند مقدار صفر و هنگامی که مقادیر ورودی به سمت صفر میل می‌کند مقدار تابع به سمت ۰/۵ و هنگامی که مقادیر ورودی به سمت اعداد مثبت بزرگ میل می‌کند مقدار تابع به سمت یک میل می کند. فرم این تابع مطابق شکل زیر بوده و به صورت رابطه زیر تعریف می شود:

(۱-۳)

$$f(n) = sig(n) = \frac{1}{1 + e^{-n}}$$

۳- ۸-۱- تابع تحریک تانژانت ها یپربولیک

تابع تحریک دیگر که به عنوان مدل ریاضی مورد استفاده قرار می‌گیرد، تابع تانژانت هایپربولیک است که از نظر شکل شبیه تابع منطقی است:

(۲-۳)

$$f(n) = \tanh(n) = \frac{e^{n} - e^{-n}}{e^{n} + e^{-n}}$$

توابع هایپربولیک با سیگموئید و گوسین، به ترتیب توابع تانژانت هایپربولیک و سکانت هایپربولیک هستند. شکل (۳- ۳) رفتار هر تابع را نشان می‌دهد.

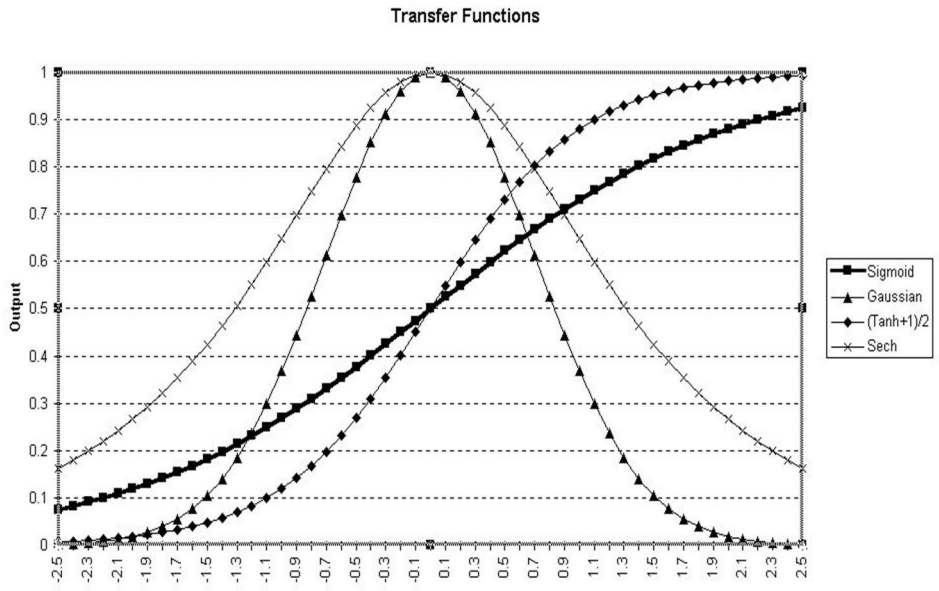

شکل ۳- ۳- توابع انتقال سیگوئید، گوسین ، تانژانت هاپربولیک و سکانت هایپربولیک (راهنمای نرم افزار Qnet).

۳-۹- مراحل یادگیری

۱- مقداردهی اولیه (Initialization): وزن‌های اولیه به تصادف در محدوده مورد نظر انتخاب می‌شوند.

۲- فعال‌سازی (Activation): نرون یا پروسپترون با به کار بردن ورودی‌ها و خروجی‌های مطلوب فعال می‌شوند.(مقداردهی) خروجی واقعی با تکرار محاسبه می‌شود.

۳- آموزش دادن (Weight training): وزن‌های نرون یا پروسپترون تغییر می‌کنند. تصحیح وزن با استفاده از یکی از الگوریتم‌های آموزش صورت می‌گیرد.

۴- تکرار(Iteration): افزایش مقدار تکرار p و برگشتن به مرحله دو و تکرار پروسه تا زمان همگرایی.

۳-۱۰- انواع یادگیری در شبکه عصبی مصنوعی

از نظر یادگیری شبکه عصبی به دو دسته تقسیم می‌شوند(آندرسون، ۱۹۹۵).

۳-۱۰-۱- یادگیری نظارت نشده یا بدون ناظر

در این نوع یادگیری هیچ سیگنالی که اطلاعات را در مورد مطلوبیت جواب شبکه به خود شبکه وارد نماید وجود ندارد. به عبارت دیگر به شبکه گفته نمی‌شود که خروجی هدف چه است و یا اینکه جواب شبکه چقدر مطلوب است. در این حالت شبکه با دریافت اطلاعات ورودی و شاخص‌های موجود در ورودی‌ها ،ارتباط بین الگوهای ورودی را پیدا کند و در خروجی کد کند.

۳-۱۰-۲- یادگیری نظارت شده یا با ناظر

در این نوع آموزش به الگوریتم یادگیری مجموعه‌ای از زوج داده که به داده‌های یادگیری مرسوم هستند داده می‌شود. هر داده یادگیری شامل ورودی به شبکه و خروجی هدف است. پس از اعمال ورودی به شبکه خروجی با خروجی هدف مقایسه می‌گردد و سپس خطای یادگیری محاسبه شده و از آن جهت تنظیم پارامترهای شبکه (وزن) استفاده می‌گردد به گونه‌ای که اگر دفعه بعد به شبکه همان ورودی را دادیم خروجی شبکه به خروجی هدف نزدیک گردد. پس در این حالت جواب شبکه برای آن تعریف شده است.

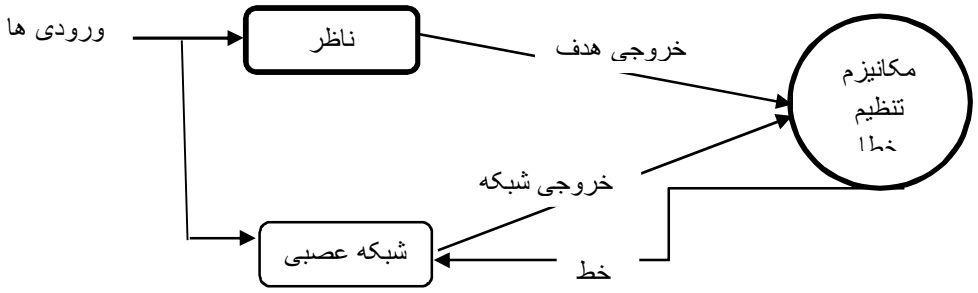

شکل ۳- ۴- نمایی از یادگیری نظارت شده یا با ناظر(منهاج، ۱۳۸۱)

۳-۱۱- انواع شبکه‌های عصبی مصنوعی

- ✓ پروسپترون چندلایه (Multi-layer percepetron)
- ✓ شبکه هاپفیلد (Hopfield Net)
- ✓ نقشه کوهونن (Kohonen Feature Map)
- ✓ تئوری رزونانس انطباقی (Theory Adaptive Resonance)

۳-۱۲- ویژگی مهم شبکه **(MLP)**

ویژگی‌های مهم شبکه MLP به شرح زیر است(منهاج،۱۳۷۷).

۱- معادل بودن ورودی‌ها با ورودی‌های سیستم

۲- توانایی فراگیری به صورت گروهی و الگو به الگو

۳- ساختار استاتیک

۳- ۱۳- کاربردهای شبکه **MLP** به شرح زیر است(فاطمی، ۲۰۰۲).

۱- برای شناسایی ویژگی

۲- رسته بندی و کلاسه بندی

۳- برای یافتن نگاشت‌های نامعلوم

۳- ۱۴- ماشین بردار پشتیبان **(Support vector machines SVM)**

استفاده از ماشین‌های بردار پشتیبان (SVM) که توسط وپنیک ارائه شد، بعنوان یکی از راه حل‌ها در یادگیری ماشین و تشخیص الگو گسترش یافته است. SVM پیشگویی‌های خود را با استفاده از ترکیبی خطی از تابع Kernel که بر روی مجموعه‌ای

از داده‌های آموزشی با نام بردارهای پشتیبان عمل می‌کند، انجام می‌دهد. ویژگی‌های یک SVM به مقدار زیادی به انتخاب kernel آن مربوط می‌شود. تعلیم SVM منجر به یک مسئله‌ی برنامه‌ریزی درجه‌ی دوم (QP) از نوع مقید می‌گردد که حل آن برای حجم زیادی از نمونه‌ها می‌تواند با روش‌های عددی بسیار مشکل باشد، لذا برای ساده کردن حل این مسئله‌ی بهینه‌سازی، روش‌های متعددی ارائه گردیده که متناسب با نیاز قابل استفاده و پیاده‌سازی می‌باشند (فتاحی، ۱۳۹۳).

در حالت کلی یادگیری ماشین به دو شکل نظارت شده و نظارت نشده انجام می‌شود. بسیاری از روش‌های یادگیری ماشین که به صورت نظارت شده عمل می‌نمایند، به این صورت کار می‌کنند که مجموعه‌ای از بردارهای ورودی مانند $X=\{nx\}$ داده می‌شود. هدف این است که ماشین قادر باشد با استفاده از این داده‌های آموزشی برای ورودی x جدید، t را پیش‌بینی نماید(پیشاپ و تاپینگ، ۲۰۰۰).

در این راستا می‌توان دو حالت متمایز را در نظر گرفت: رگرسیون (Regression) ، که در آن t یک متغیر پیوسته است و طبقه‌بندی کردن (Classification) ، که در آن t متعلق به یک مجموعه‌ی گسسته می‌باشد. بسیاری از مسائل یادگیری ماشین اساساً در دسته دوم واقع می‌شوند و هدف تعلیم ماشین به گونه‌ای ست که ماشین بتواند بخوبی این دسته‌بندی را انجام دهد.

۳- ۱۵- کاربردهای SVM

۱- تشخیص و شناسایی چهره

۲- تشخیص و شناسایی اشیاء

۳- تشخیص دست نوشته و ارقام

۴- تشخیص صحبت و گوینده

۵- بازیابی تصاویر و اطلاعات

۶- پیش‌بینی

۷- سایر کاربردها

۳-۱۶- مزایا و محدودیت‌های SVM

روش بردارهای پشتیبان یک روش بسیار کارا در دسته‌بندی داده‌ها می‌باشد از این رو یکی از ابزارهای مهم در یادگیری ماشین از نوع نظارت شده می‌باشد. این روش علاوه بر تمامی نقاط قوت خود محدودیت‌هایی را نیز دارا می‌باشد. بزرگترین محدودیت روش بردارهای پشتیبان در انتخاب Kernel می‌باشد. زمانی که Kernel ثابت باشد، طبقه‌بندی SVM تنها دارای یک پارامتر قابل تغییر توسط کاربر می‌باشد (پارامتر جریمه‌ی خطا) انتخاب بهترین Kernel برای یک مسئله‌ی خاص از مسائل مهم و مطرح می‌باشد.

دومین محدودیت در سرعت و اندازه در آموزش و تست می‌باشد. آموزش پایگاه داده های بسیار بزرگ، مسئله ای غیرقابل حل به روش عددی می‌باشد. راه حل‌هایی برای این قبیل از مسائل ارائه گردید. داده‌های گسسته مشکل دیگری را سبب می‌شوند، هرچند با مقیاس بندی‌های مجدد می‌توان به نتایج خوبی رسید.

یکی دیگر از مسائل، مشکل در طراحی تفکیک کننده برای SVM چند کلاسه می‌باشد. این روش به نسبت سایر روش‌های کلاسه‌بندی داده‌ها مانند Neural Network در صورتیکه انتخاب‌ها مناسب انجام شوند از دقت بسیار خوب و بالایی برخوردار می‌باشد و درکارهایی نظیر شناسایی الگو و شناسایی دست خط کارایی بالایی را به نمایش گذارده است.

۳-۱۷- ابزارهای پیاده سازی SVM

برای استفاده از طبقه‌بندی کننده SVM ابزارها و زیرساخت‌های مختلفی ایجاد شده است که هر کدام ویژگی‌ها و امکانات خاصی را ارائه می‌دهند. در این بخش به تعدادی از معروفترین این ابزارها :

۳-۱۷-۱- MATLAB

یکی از ابزارهای مهم در این زمینه دستورات تعبیه شده در نرم افزار MATLAB می‌باشد. در MATLAB علاوه بر اینکه راهنمای خوبی برای آشنایی با مفهوم ماشین‌های بردار پشتیبان، ارائه شده‌است دستوراتی نیز برای کار با SVM طراحی شده است. مانند هر مدل یادگیری نظارت شده‌ای در MATLAB نیز ابتدا ماشین بردار پشتیبان توسط داده‌های تعلیمی آموزش داده‌شده، سپس از ماشین تعلیم دیده برای دسته‌بندی(پیش بینی) داده‌های جدید استفاده می‌گردد. بعلاوه برای رسیدن به دقت پیش‌بینی مناسب، می‌توان از توابع هسته‌ی مختلف استفاده نمود که پارامترهای این توابع هسته، قابل تنظیم می‌باشند.

آموزش دسته‌بندی کننده‌ی SVM در MATLAB با استفاده از دستور SVMtrain انجام می‌شود.

۳-۱۷-۲- LIBSVM

بسته‌ی دیگری که برای کار با SVM ارائه شده است LIBSVM می‌باشد که به صورت مجموعه‌ای از توابع کتابخانه‌ای توسط Chih Chung Chang and Chih Jenlin ارائه شده است. این مجموعه دارای امکانات فراوانی برای استفاده از svm می‌باشد که برخی از آن‌ها در زیر آمده‌اند:

- برای کاربردهای کلاسه‌بندی، رگرسیون و تخمین توزیع شده قابل استفاده می‌باشد.

- از دسته‌بندی چند کلاسه پشتیبانی می‌نماید.

- حمایت از تخمین احتمالاتی

- از توابع هسته‌ی گوناگون استفاده می‌نماید، ضمن آنکه ماتریس هسته در آن‌ها از قبل محاسبه شده‌است.

- منابع آن به دو زبان C++ و Java موجود می‌باشد.

- در زبان‌ها و محیط‌های مختلف قابل استفاده می‌باشد.

- از نسخه‌ی ۲.۸ به بعد از روش SMO استفاده می‌نماید.

همچنین چندین دیتاست مختلف توسط ارائه دهندگان LIBSVM طراحی و آماده‌ی استفاده می‌باشد.

آخرین نسخه‌ی این بسته تا آوریل۲۰۱۴ ، نسخه‌ی ۳.۱۸ می‌باشد که منتشر شده است.

۳-۱۷- ۳ - **Svm struct matlab**

Svm struct matlab عنوان بسته‌ای است که توسط Andea Vedadi برای استفاده‌ی ساده تر و کارآمدتر از SVM در MATLAB به صورت مجموعه‌ای از توابع پیاده‌سازی شده است که در MATLAB قابل فراخوانی و استفاده می‌باشد.

۳- ۱۸- شاخص های ارزیابی

برای اجرای مدل‌ها، داده‌ها به صورت ۸۰٪ و ۲۰٪ به ترتیب برای مرحله آموزش و تست تفکیک شدند و همچنین به منظور محاسبه مقادیر ضریب تبیین (R squared, R^2) میانگین مجذور ریشه خطا (Root Mean Squared Error, RMSE) و میانگین خطا مطلق (Mean Absolute Error, MAE) به ترتیب از فرمول‌های (۳-۳)، (۳-۴) و (۳-۵) استفاده گردید.

- ضریب همبستگی[1] (R): این شاخص نشان دهنده درجه اعتبار بین دو متغیر می‌باشد. ضریب همبستگی به صورت زیر تعریف می‌شود:

$$R^2 = \frac{\Sigma(X-\overline{X})(Y-\overline{Y})}{\sqrt{\Sigma(X-\overline{X})^2\,\Sigma(Y-\overline{Y})^2}} \qquad (۳-۳)$$

که در آن X مقدار واقعی، Y مقدار پیش‌بینی شده برای X و $\bar{X}$ و $\bar{Y}$ میانگین Xها و Yها می‌باشد.

مقادیر بالای R نشان دهنده ارتباط قوی بین مقادیر واقعی و مقادیر پیش‌بینی شده است و در مقابل پایین R ارتباط ضعیفی و عدم ارتباط بین مقادیر را نشان می‌دهد(کندی و نویل، ۱۹۶۴).

اسمیس محدوده زیر را برای ارزیابی R بین صفر و یک پیشنهاد کرده است: (اسمیس، ۱۹۸۶).

همبستگی قوی بین دو دسته متغیر وجود دارد.	$\lvert R\rvert \geq 0.8$
همبستگی بین دو دسته متغیر وجود دارد.	$0.2 < \lvert R\rvert < 0.8$
همبستگی بسیار ضعیف بین دو دسته متغیر وجود دارد.	$\lvert R\rvert \leq 0.2$

این شاخص بین بین مجموعه خروجی‌های واقعی و نتایج حاصل از پیش‌بینی مدل برازش خطی انجام می‌دهد. نزدیک بودن نتایج مدل به خط X = Y مبنای قوی بودن همبستگی است(کورتس و وپنیک، ۱۹۹۵).

- جذر میانگین مربعات خطا[2] (RMSE): این شاخص متوسط مقدار خطا بین نتایج خروجی و مقدار واقعی را بیان می‌کند. همچنین از توان دوم این شاخص (MSE) در روند

[1] Coefficient of Correlation
[2] Root Mean Square Error

محاسبات همگرایی شبکه استفاده می‌شود، زیرا این شاخص تمرکز بیشتری روی خطاهای بزرگتر دارد(هت نیلان، ۱۹۹۰).

$$RMSE = \sqrt{1/n \sum_{i=1}^{n} (X_O - X_P)^2} \quad (۴-۳)$$

$$MAE = \frac{1}{n} \sum_{i=1}^{n} \left| X_O - \hat{X}_P \right| \quad (۵-۳)$$

که در آن‌ها: X_0 مقادیر پیش‌بینی شده، $\widehat{Xp}$ و Xp مقادیر مشاهداتی و n تعداد داده‌ها می‌باشد.

فصل چهارم

بحث و نتایج

۴-۱- مقدمه

در این فصل نتایج حاصل از مدل‌سازی ازت و گوگرد خاک که توسط نرم افزارQnet انجام شده و نتایج حاصل از SVM که با نرم افزار متلب به دست آمده و نتایج حاصل از رگرسیون خطی چند متغییره که با نرم افزار SPSS به دست آمده ارائه می‌گردد.

۴-۲- نتایج اندازه‌گیری خصوصیات فیزیکی و شیمیایی خاک

متغیرهای مورد مطالعه بر روی ۱۰۰ نمونه خاک اخذ شده از عمق ۰-۳۰ زراعی به روش‌های استاندارد آزمایشگاهی (توضیحات در فصل ۳) اندازه‌گیری گردید. به منظور بررسی چگونگی توزیع داده‌ها و دستیابی به خلاصه‌ای از اطلاعات آماری و ویژگی‌های آن‌ها شامل حداقل، حداکثر، میانگین، دامنه تغییرات، انحراف معیار، واریانس، چولگی و کشیدگی، توسط نرم افزار SPSS مورد بررسی قرار گرفت. جدول (۴-۱) توصیف آماری متغیرهای فیزیکی و شیمیایی اندازه‌گیری شده خاک را نشان می‌دهند.

برای بررسی نرمال بودن داده‌ها می‌توان از ضریب چولگی و ضریب کشیدگی داده‌ها استفاده نمود. اگر ضریب چولگی بین مقادیر ۲+ و ۲- و ضریب کشیدگی بین مقادیر ۳+ و ۳- باشد، داده‌ها نرمال بوده و نیازی به نرمال سازی نمی‌باشد(جورج و مالری، ۲۰۱۰). همان‌طور که جدول (۴-۱) نشان می‌دهد، مقادیر ضریب چولگی و کشیدگی در دامنه اعداد ذکر شده قرار دارند، بنابراین در این پژوهش، داده‌های مورد استفاده برای مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان و رگرسیون، بدون نرمال‌سازی مورد استفاده قرار گرفتند.

جدول۴- ۱- توصیف آماری متغیرهای فیزیکی و شیمیایی اندازه‌گیری شده خاک

پارامتر	واحد اندازه‌گیری	حداقل	حداکثر	میانگین	دامنه تغییرات	واریانس	انحراف معیار	چولگی	کشیدگی
رس	%	۰/۳۴	۷۸/۵۲۰	۳۳/۷۰۶	۷۸/۴۸۶	۲۳۸/۲۵۲	۱۵/۴۳۵	۰/۷۰۸	۰/۵۸۶
سیلت	%	۷/۰۸	۷۲	۳۸/۰۸۱۶	۶۴/۹۲	۲۲۳/۳۲۸	۱۴/۹۴۴	۰/۱۳۳	-۰/۵۰۵
شن	%	۷/۴۴	۵۶/۷۶	۲۸/۱۲۵۹	۴۹/۳۲	۱۴۳/۴۲۷	۱۱/۹۷۶	۰/۴۵۲	-۰/۶۴۵
واکنش خاک	-	۷/۸۰	۹/۰۳۰	۸/۴۲۶۲۱	۱/۲۳۰	۰/۰۷۵	۰/۲۷۳۹	۰/۰۵۲	-۰/۷۷۹
درصد شوری	dS/m	۰/۲۰	۲/۴۷	۰/۸۱۸۶	۲/۴۵۰۵	۰/۲۷۸	۰/۵۲۷۴	۰/۷۷۲	۰/۲۸
کربن آلی	%	۰/۵۴۶	۴/۰۳۶	۱/۹۶۵۲	۳/۴۹	۰/۷۵۷	۰/۸۷	۰/۸۱۲	-۰/۰۹۳
نیتروژن	%	۰/۱۱۲۰	۰/۴۱۳۰	./۱۵۰۹	۰/۴۰۱۸	۰/۰۰۵	۰/۰۷۳	۰/۹۸۷	۱/۶۱۸
گوگرد	$mgkg^{-1}$	۲/۵۵	۳۳/۸۴۶	۱۱/۳۲۵۴	۳۶/۳۹	۸۲/۷۷۸	۹/۰۹۸	۰/۹۸۲	۰/۰۲۷

۴-۲-۱- وضعیت واکنش خاک

همانطور که در جدول (۴-۱) نشان می‌دهد، حداکثر، حداقل و میانگین pH خاک منطقه مورد مطالعه در عمق ۰تا ۳۰ سانتی متری به ترتیب برابر ۹/۰۳۰، ۷/۸۰ و ۸/۴۲ می‌باشد. با توجه به نتایج بدست آمده، خاک سطحی منطقه مورد مطالعه دارای pH قلیایی است که می‌تواند بسیاری از ویژگی‌های شیمیایی، حاصلخیزی، رشد گیاه و فعالیت ریز جانداران خاک و جذب و انتقال عناصر در خاک تحت تأثیر قرار دهد. بسیاری از واکنش‌های شیمیایی موثر بر غلظت عناصر در خاک و فعالیت موجودات زنده نیز به اسیدیته خاک وابسته بوده و بر اساس پژوهش‌های انجام شده pH بین ۵ تا ۹ محدوده مناسبی جهت فعالیت‌های زیستی بیان شده است (آیرز، ۱۹۸۵). لذا بایستی نسبت به کاهش pH خاک اقدام نمود.

۴- ۲- ۲- وضعیت شوری خاک

همانطور که در جدول (۴-۱) نشان می‌دهد میزان حداقل، حداکثر و میانگین EC خاک منطقه مورد مطالعه در عمق ۰تا ۳۰ سانتی متری به ترتیب برابر ۰/۲۰، ۲/۴۷ و ۰/۸۱۸۶ می‌باشد. با توجه به نتایج به دست آمده نشان دهنده شوری کم خاک منطقه مورد مطالعه می‌باشد و اگر هدایت هیدرولیکی خاک بالای ۴ دسی زیمنس بر متر باشد خاک شور می‌باشد.

تحمل گیاهان مختلف در برابر شوری متفاوت است. بر این اساس می‌توان گیاهان را به چهار دسته تقسیم کرد گروه متحمل، نیمه متحمل، نیمه‌حساس و حساس. تاثیر شوری بر گیاهان بسته به نوع گیاه، نوع گونه و مرحله رشد گیاه متفاوت است.

۴- ۲- ۳- وضعیت درصد کربن آلی خاک

جدول (۴-۱) نشان می‌دهد که کربن آلی درخاک منطقه مورد مطالعه در محدوده‌ی ۰/۵۴۶ تا ۴/۰۳۶ درصد متغیر و میانگین آن ۱/۹۶ درصد می‌باشد. با توجه به اینکه کربن آلی یکی از مهم ترین فاکتورها در رشد و نمو گیاهان می‌باشد در اکثر مناطق مورد مطالعه درصد کربن آلی مناسب می‌باشد. نقش اساسی کربن آلی خاک در اکوسیستم‌های کشاورزی، تامین مواد غذایی و انرژی برای موجودات زنده و گیاهان خاک است(پوگت و همکاران، ۲۰۰۱). کربن آلی نقش مهمی در خصوصیات بیولوژیکی (فراهمی اجزا و مواد غذایی مورد نیاز جمعیت میکروبی خاک)، ویژگی‌های شیمیایی(تغییرات pH و قدرت بافری خاک) و فیزیکی خاک(پایداری ساختمان خاک) داشته وتاثیر قابل توجهی روی برهم کنش‌های خاک و گیاه می گذارد(هانگ و همکاران، ۲۰۰۷).

۴- ۲- ۴- وضعیت درصد نیتروژن خاک

جـدول شـماره (۴-۱) بیـانگر حـداقل و حـداکثر میـزان درصـد نیتـروژن بـه ترتیـب برابـر بـا ۰/۱۱۲۰ و ۰/۴۱۳۰ مـی‌باشـد. همچنـین حـداقل و حـداکثر میـزان درصـد کـربن آلـی بـه ترتیـب برابر با ۰/۵۴۶ و ۴/۰۳۶ درصد نشان می‌دهد.

نیتـروژن پـر مصـرف‌تـرین عنصـر مـورد نیـاز بـرنج و یکـی از عوامـل اصـلی افـزایش میـزان محصـول اسـت. ایـن عنصـر مهـم‌تـرین نهـاده تولیـد و محدودکننـده‌تـرین عنصـر غـذایی در تولیـد بـرنج در گسـترده جهـانی محسـوب و سـبب تسـریع پنجـه زدن و رشـد گیـاه مـی‌شـود. کمبـود نیتروژن در خاک یـا پـایین بـودن مقـدار آن از حـد مـورد نیـاز، سـبب ناهمـاهنگی در رشـد، ارتفـاع کوتاه گیاه و تعداد پنجه‌هـا کمتـر از حـد اسـتاندارد مـی‌شـود، همچنـین بـرگ هـا در برخـی مـوارد رو به زردی و لکه دار شدن مـی‌گذارنـد. ایـن عنصـر بـه رشـد سـریع گیـاه (افـزایش ارتفـاع و تعـداد پنجـه)، افـزایش انـدازه بـرگ، تعـداد دانـه در خوشـه، درصـد دانـه‌هـای پـر در هـر خوشـه، مقـدار پروتئین دانه و وزن هـزار دانـه کمـک مـی‌نمایـد. بنـابراین نیتـروژن تمـامی مشخصـه‌هـای مـؤثر بـر عملکرد را تحت تأثیر قرار می‌دهد (موسسه تحقیقات برنج ۱۳۹۱).

۴- ۲- ۵- وضعیت گوگرد خاک

جـدول (۴-۱) بیـانگر حـداقل و حـداکثر میـزان گـوگرد قابـل جـذب برابـر بـا ۲/۵۵ و ۳۳/۸۴ میلی گرم بر کیلوگرم می‌باشد. همچنین نشان می‌دهد دامنه تغییرات برابر ۳۶/۳۹می‌باشد.

کمبـود گـوگرد شـبیه نیتـروژن اسـت بـا ایـن تفـاوت کـه زردی حاصـل از کمبـود گـوگرد را در بـرگ‌هـای بـالایی مشـاهده مـی‌شـود. هـر چقـدر نیـاز گیـاه بـه گـوگرد بیشـتر باشـد، گـوگرد بیشتری از طریـق برداشـت خـارج مـی‌شـود. غـلات نیـاز کمتـری بـه گـوگرد دارنـد امـا گیاهـان روغنی نیازشـان بـه گـوگرد بیشـتر اسـت. بقـولات از نظـر نیـاز بـه عنصـر گـوگرد در حـد واسـط غلات و گیاهان روغنی قرار دارند (موسسه تحقیقات برنج ۱۳۹۱).

۴-۳- بررسی همبستگی پارامترها

به منظور بررسی همبستگی پارامترهای ورودی با مقادیر عناصرازت و گوگرد خاک از نرم‌افزار SPSS استفاده شد و جداول همبستگی (۴-۲) و (۴-۳) و به دست آمد.

براساس نتایج بدست آمده از جدول (۴-۲) همبستگی برای عنصر نیتروژن و پارامترهای خاک به عنوان داده‌های ورودی که قابل محاسبه‌اند نشان می‌دهد که بیشترین میزان همبستگی را کربن آلی با نیتروژن خاک دارد. به طوری که کربن آلی با ۰/۳۹۷ همبستگی در ازت نشان از رابطه شدید این دو پارامتر با یکدیگر را دارد به طوری که میزان نیتروژن کل نیز خود تابعی از کربن آلی است و تاثیرگذاری آن وابسته به کربن آلی است. همچنین جدول (۴-۳) نشان می‌دهد که گوگرد بیشترین میزان همبستگی را با شوری خاک، سیلت، کربن آلی سپس رس دارد. به طوری که شوری خاک با ۰/۶۲۷، سیلت با ۰/۳۳۴ رابطه معکوس، کربن آلی با ۰/۲۹۳ و رس با ۰/۲۲۷ همبستگی در گوگرد خاک نشان از رابطه شدید این پارامترها دارد.

جدول ۴-۲ - همبستگی میان پارامترهای زودیافت خاک با میزان ازت خاک

پارامتر	ازت	pH	EC	شن	رس	سیلت	کربن آلی
ازت	۱	-/۰۴۶	۰/۱۹۲	-۰/۰۱۸	-۰/۰۲۱	۰/۰۴۰	۰/۳۹۷**
pH		۱	۰/۳۱۱**	۰/۱۰۰	۰/۰۸۶	-۰/۱۹۵	۰/۳۲۴**
EC			۱	۰/۲۴۳**	۰/۲۰۹*	-۰/۴۶۰**	۰/۴۶۲**
شن				۱	-۰/۴۰۲**	-۰/۳۶۸**	۰/۰۳۱
رس					۱	-۰/۶۷۱**	۰/۲۸۵**
سیلت						۱	-۰/۳۴۷**
کربن آلی							۱

جدول ۴-۳ - همبستگی میان پارامترهای زودیافت خاک با میزان گوگرد خاک

	گوگرد	pH	EC	شن	رس	سیلت	کربن آلی
گوگرد	۱	۰/۲۱۷*	۰/۶۲۷**	۰/۱۲۵	۰/۲۲۷**	-۰/۳۳۴**	۰/۲۹۳**
pH		۱	۰/۳۱۱**	۰/۱۰۰	۰/۰۸۶	-۰/۱۹۵	۰/۳۲۴**
EC			۱	۰/۲۴۳**	۰/۲۰۹*	-۰/۴۶۰**	۰/۴۶۲**
شن				۱	-۰/۴۰۲**	-۰/۳۶۸**	۰/۰۳۱
رس					۱	-۰/۶۷۱**	۰/۲۸۵**
سیلت						۱	-۰/۳۴۷**
کربن آلی							۱

۴-۴- بررسی تاثیر توابع انتقال در یادگیری شبکه عصبی مصنوعی

توابع انتقال سیگموید، گوسین، تانژانت هایپروبولیک و سکانت هایپروبولیک برای ازت و گوگرد خاک مورد بررسی قرار گرفتند. که نتایج آن در جدول(۴-۴) و (۴-۵) نشان داده شده است. همانطور که نتایج جدول (۴-۴) نشان می‌دهد مدل شبکه عصبی مصنوعی توانسته است ازت خاک را با تابع سیگموید و یک لایه پنهان با ضریب تبیین ۰/۷۷، ۰/۶۶ ، RMSE ۰/۰۵۱، ۰/۰۴۷ و MAE ۰/۰۳۹، ۰/۰۳۵ به ترتیب برای مرحله آموزش و تست پیش‌بینی کند همچنین زمانی که تابع انتقال به گوسین تغییر یافت مقادیر ضریب تبیین

۰/۷۶، ۰/۴۰، RMSE ۰/۰۵۲، ۰/۰۵۷ و MAE ۰/۰۴۰، ۰/۰۴۳ به ترتیب برای مرحله آموزش و تست تغییر کرد و با انتقال تابع به تانژانت هایپروبولیک ضریب تبیین ۰/۶۹، ۰/۴۷، RMSE ۰/۰۵۷، ۰/۰۴۷ و MAE ۰/۰۴۱، ۰/۰۳۱ به ترتیب برای مرحله آموزش و تست پیش‌بینی شد و همچنین با انتقال تابع به سکانت هایپروبولیک ضریب تبیین ۰/۷۶، ۰/۳۶، RMSE ۰/۰۵۲، ۰/۰۵۹ و MAE ۰/۰۴۰، ۰/۰۳۱ به ترتیب برای مرحله آموزش و تست پیش‌بینی شد.

همچنین نتایج جدول (۴-۵) نشان می‌دهد مدل شبکه عصبی مصنوعی توانسته است گوگرد خاک را با تابع سیگموید و یک لایه پنهان با ضریب تبیین ۰/۸۰، ۰/۲۰ ، RMSE ۵/۷۳۴، ۶/۵۳۷ و MAE ۴/۳۷۴، ۴/۹۳۷ به ترتیب برای مرحله آموزش و تست پیش‌بینی کند همچنین زمانی که تابع انتقال به گوسین تغییر یافت مقادیر ضریب تبیین ۰/۷۶، ۰/۱۳، RMSE ۶/۲۶۶، ۵/۳۶۳ و MAE ۴/۸۸۳، ۴/۳۲۲ به ترتیب برای مرحله آموزش و تست تغییر کرد و با انتقال تابع به تانژانت هایپروبولیک ضریب تبیین ۰/۸۳، ۰/۲۵، RMSE ۵/۴۰۱، ۵/۵۷۴ و MAE ۴/۱۴۲، ۴/۱۰۹ به ترتیب برای مرحله آموزش و تست پیش‌بینی شد و همچنین با انتقال تابع به سکانت هایپروبولیک ضریب تبیین ۰/۷۷، ۰/۰۷۴، RMSE ۶/۰۸۱، ۸/۲۵۹ و MAE ۴/۹۰۲، ۶/۵۶۶ به ترتیب برای مرحله آموزش و تست پیش‌بینی شد.

که این پیش‌بینی‌ها نشان می‌دهد که نوع تابع انتقال در آموزش و یادگیری شبکه عصبی مصنوعی تاثیردارد بنابراین مدل با ساختار مختلف مورد بررسی قرار گرفت.

برای ازت تابع انتقال هایپربولیک سکانت با ضریب تبیین ۰/۸۶، ۰/۶۰، RMSE ۰/۰۴۰، ۰/۰۵۷ و MAE ۰/۰۳۲، ۰/۰۴۲ به ترتیب برای مراحل آموزش و تست و برای گوگرد تابع انتقال گوسین با ضریب تبیین ۰/۸۴، ۰/۴۳، RMSE ۴/۵۴۱، ۱۰/۰۰۷ و MAE ۳/۱۴۷، ۶/۶۸۹ به ترتیب برای مراحل آموزش و تست بهترین کارایی را داشته‌اند.

جدول ۴- ۴- نتایج حاصل از اجرای توابع انتقال مختلف برای تخمین ازت خاک

عنصر	تعداد لایه های پنهان	تابع محرک	مرحله محاسباتی	R^2	RMSE	MAE
		سیگموید	آموزش	۰/۷۷	۰/۰۵۱	۰/۰۳۹
			تست	۰/۶۶	۰/۰۴۷	۰/۰۳۵
		گوسین	آموزش	۰/۷۶	۰/۰۵۲	۰/۰۴۰
ازت	۱		تست	۰/۴۰	۰/۰۵۷	۰/۰۴۳
		تانژانت	آموزش	۰/۶۹	۰/۰۵۷	۰/۰۴۱
		هایپروبولیک	تست	۰/۴۷	۰/۰۴۷	۰/۰۳۱
		سکانت	آموزش	۰/۷۶	۰/۰۵۲	۰/۰۴۰
		هایپروبولیک	تست	۰/۳۶	۰/۰۵۹	۰/۰۴۵

جدول ۴- ۵- نتایج حاصل از اجرای توابع انتقال مختلف برای تخمین گوگرد خاک

عنصر	تعداد لایه های پنهان	تابع محرک	مرحله محاسباتی	R^2	RMSE	MAE
		سیگموید	آموزش	۰/۸۰	۵/۷۳۴	۴/۳۷۴
			تست	۰/۲۰	۶/۵۳۷	۴/۹۳۷
		گوسین	آموزش	۰/۷۶	۶/۲۶۶	۴/۸۸۳
گوگرد	۱		تست	۰/۱۳	۵/۳۶۳	۴/۳۲۲
		تانژانت	آموزش	۰/۸۳	۵/۴۰۱	۴/۱۴۲
		هایپروبولیک	تست	۰/۲۵	۵/۵۷۴	۴/۱۰۹
		سکانت	آموزش	۰/۷۷	۶/۰۸۱	۴/۹۰۲
		هایپروبولیک	تست	۰/۷۴	۸/۲۵۹	۶/۵۶۶

۴- ۵- بررسی تاثیر لایه های پنهان در یادگیری شبکه عصبی مصنوعی

پس از تغییر درتعداد لایه پنهان و تکرار حین آموزش شبکه این نتیجه حاصل شد که شبکه مورد استفاده تا ۳ لایه پنهان با ۶ نورون در لایه میانی بیشترین میزان دقت و کمترین

میـــزان خطـــا را دارد و بـــالاتر از ۳ لایـــه پنهـــان بـــا ۶ نـــورون در لایـــه میـــانی کمتـــرین دقـــت و بیشترین مقدار خطا را دارد.

شـــکل‌هـــای (۴-۱) و (۴-۲) منحنـــی تغییـــرات RMSE را در لایـــه‌هـــای پنهـــان مختلـــف بـــرای ازت و گوگرد نشان می‌دهد. با توجـه بـه شـکل ملاحظـه مـی‌شـود ازت بـا سـه لایـه پنهـان و مقـدار RMSE =۰/۰۴۰ و گـوگرد بـا سـه لایـه پنهـان و مقـدار RMSE =۴/۵۴۱ کمتـرین مقـدار خطـا را نسـبت بـه سـایر لایـه‌هـای پنهـان نشـان دادنـد، بـه عنـوان بهتـرین لایـه‌هـای پنهـان در سـاختار شـبکه انتخـاب شـدند. همـان طـور کـه در شـکل‌هـا دیـده مـی شـود تغییـرات RMSE دارای رونـد مشخصی نیست چون شبکه عصـبی یـک مـدل جعبـه سـیاه مـی‌باشـد و وزن هـا بـه طـور تصـادفی انتخاب می‌شوند نمی تـوان ایـن رونـد موجـود را بـه طـور کامـل توضـیح داد. فقـط بایـد بـا سـعی و خطا بهتـرین سـاختار را بـه دسـت آورد. بـا توجـه بـه شـکل‌هـای مربوطـه، ملاحظـه مـی‌شـود کـه حداقل ریشه مربعات خطا در هر۲ عنصر، مربوط به شبکه با ۳ نورون در لایه مخفی می‌باشد.

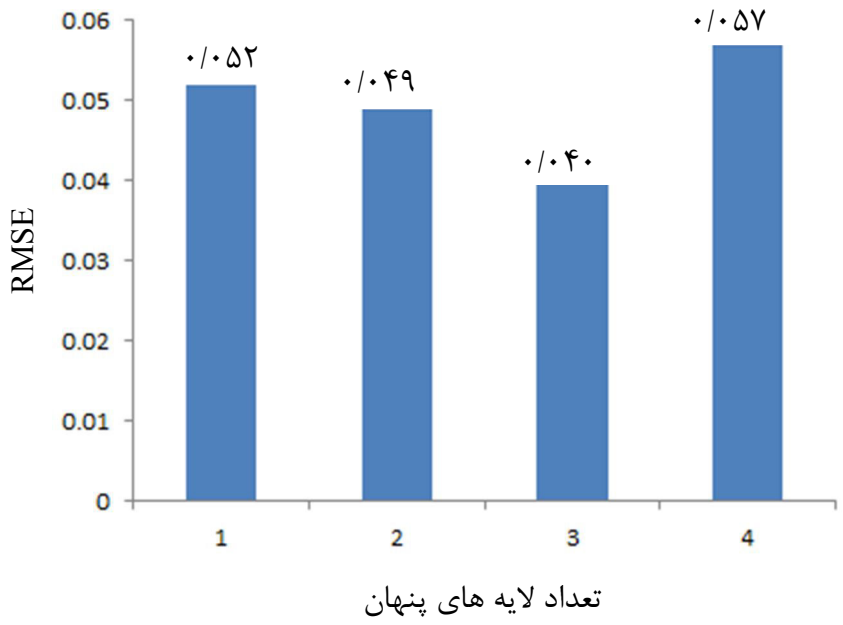

شکل ۴- ۱- مقادیر RMSE لایه های پنهان متفاوت برای ازت خاک

شکل ۴-۲- مقادیر RMSE لایه های پنهان متفاوت برای گوگرد خاک

۴-۶- انتخاب بهترین ساختار شبکه عصبی مصنوعی

در این راستا برای اجرای مدل از ساختار یک لایه ورودی، یک لایه خروجی و تعداد متفاوت از لایه میانی(لایه پنهان)(۱ الی ۴) با توابع سیگموید، گوسین، تانژانت هایپربولیک و سکانت هایپربولیک استفاده گردید.

جدول (۴-۶) نشان دهنده نتایج حاصل از اجرای مدل MLP با بهترین حالت تابع، برای تخمین عناصر دیریافت خاک توسط پارامترهای زودیافت خاک است. از آنجاییکه تعداد لایه‌های پنهان با نورون‌های لایه میانی و نوع تابع انتقال در آموزش و یادگیری شبکه عصبی مصنوعی تاثیردارد بنابراین مدل با ساختار مختلف مورد بررسی قرار گرفت. پس از تغییر در گره‌های لایه پنهان و تکرار حین آموزش شبکه این نتیجه حاصل شد که شبکه مورد استفاده با تعداد ۳ گره در لایه پنهان و ۶ نورون در لایه میانی و تعداد تکرار تا ۱۰۰۰۰۰ بیشترین میزان دقت و کمترین میزان خطا را دارد .

با توجه به جدول (۴-۶) نتایج اجرای مدل نشان می‌دهد که تابع محرک هایپربولیک سکانت با سه لایه پنهان با ۶ نورون لایه میانی و داشتن ضریب تبیین ۰/۸۶، ۰/۶۰، RMSE

۰/۰۴۰، ۰/۰۵۷ و MAE ۰/۰۳۲، ۰/۰۴۲ به ترتیب برای مراحل آموزش و تست ازت خاک و تابع محرک گوسین با سه لایه پنهان با ۶ نورون لایه میانی و داشتن ضریب تبیین ۸۸/ ۰، ۰/۴۳، RMSE ۴/۵۴۱، ۱۰/۰۰۷ و MAE ۳/۱۴۷، ۶/۶۸۹ به ترتیب برای مراحل آموزش و تست گوگرد خاک دارای نتایج بهتری نسبت به سایر توابع می‌باشد. جدول (۴-۶) نتایج حاصل از اجرای مدل MLP و بهترین توابع ذکر شده برای تخمین ازت و گوگرد خاک را نشان می‌دهد. نتایج حاصل از اجرای تعداد لایه‌های پنهان مختلف و توابع مختلف در تخمین ازت و گوگرد خاک در پیوست شماره (۱) الی (۲) آمده است. علاوه بر پارامتر ضریب تبیین (R^2) که بیشترین مقدار را در آموزش و تست دارد، پارامترهای RMSE و MAE نیز مقادیر کمتری را در دو تابع محرک ذکر شده در مرحله آموزش نشان می‌دهند.که نشان از قابلیت بالای این توابع در تخمین ازت و گوگرد خاک دارد. زیرا اتکا به پارامتر ضریب تبیین برای بررسی قابلیت‌های مختلف هر شبکه و تابع، کافی نبوده و نیاز به مطالعات گسترده‌تر آماری وجود دارد. در شکل‌های (۴-۳) الی (۴-۶) پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای ازت و گوگرد خاک برای شبکه MLP آورده شده است.

جدول ۴- ۶- نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین ازت و گوگرد خاک

عنصر	تابع محرک	تعداد لایه های پنهان	تعداد نورون	مرحله محاسباتی	ضریب تبیین (R^2)	RMSE	MAE
ازت	سکانت هایپربولیک Secant Hyperbolic	۳	۶	آموزش	۰/۸۶	۰ /۰۴۰	۰/۰۳۲
				تست	۰/۶۰	۰/۰۵۷	۰/۰۴۲
گوگرد	گوسین Gaussian	۳	۶	آموزش	۰/۸۸	۴/۵۴۱	۳/۱۴۷
				تست	۰/۴۳	۱۰/۰۰۷	۶/۶۸۹

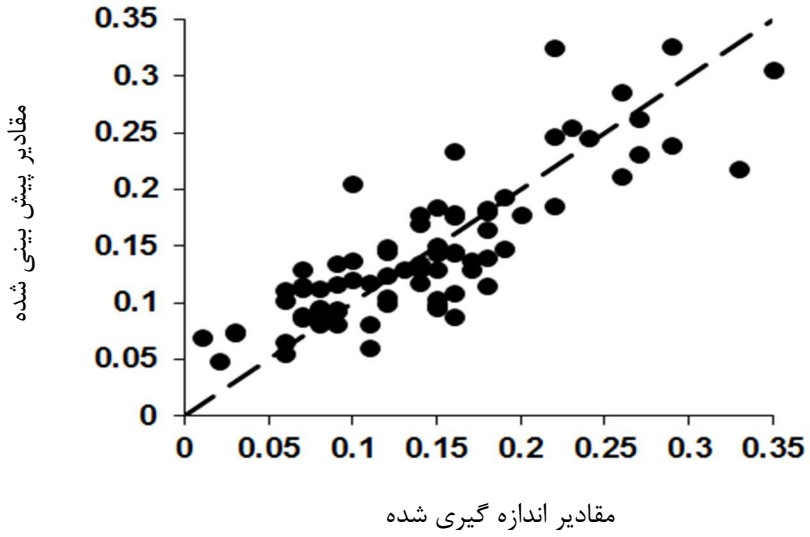

شکل ۴-۳- نمودار پراکنش داده های اندازه گیری شده و پیش بینی شده برای مرحله آموزش ازت خاک مدل شبکه عصبی مصنوعی

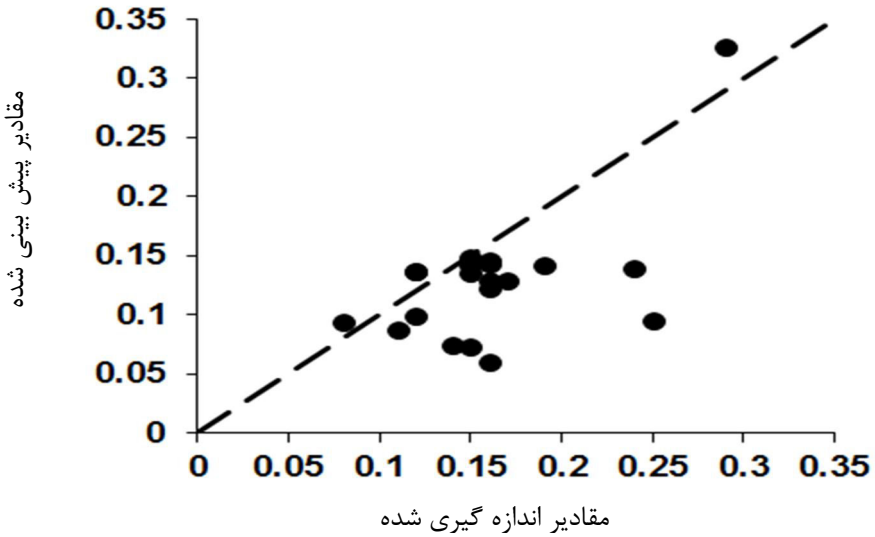

شکل ۴-۴- نمودار پراکنش داده های اندازه گیری شده و پیش بینی شده برای مرحله تست در ازت خاک مدل شبکه عصبی مصنوعی

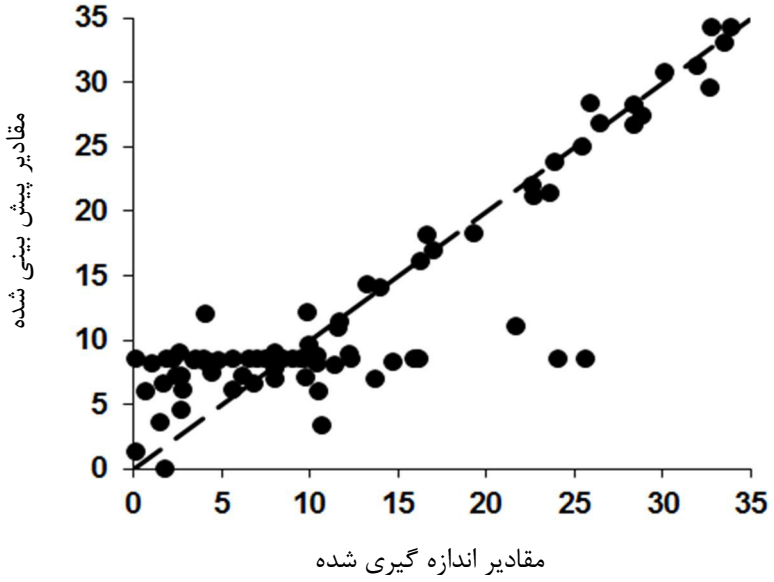

شکل ۴- ۵- نمودار پراکنش داده های اندازه گیری شده و پیش بینی شده برای مرحله آموزش در گوگرد خاک مدل شبکه عصبی مصنوعی

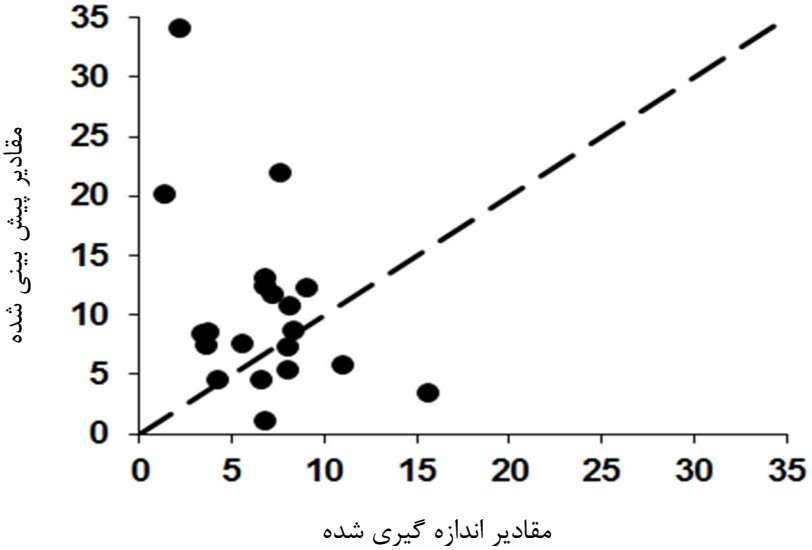

شکل ۴-۶- نمودار پراکنش داده های اندازه گیری شده و پیش بینی شده برای مرحله تست در گوگرد خاک مدل شبکه عصبی مصنوعی

۴-۷- بررسی تابع کرنل **RBF** در **SVM**

در جدول (۴-۷) نتایج حاصل از اجرای مدل ماشین بردار پشتیبان برای ازت و گوگرد خاک آورده شده است.که با توجه به آن نتایج اجرای مدل نشان می‌دهد که R^2، RMSE و MAE به ترتیب برای مراحل آموزش و تست ازت برابر با ۰/۹۹ ، ۰/۰۰۷۴ و ۰/۰۰۵۷و ۰/۷۰ ، ۰/۰۳۴۷ و ۰/۰۲۳ می‌باشد. که برای پیش‌بینی ازت و گوگرد خاک مدل ماشین بردار پشتیبان در مرحله آموزش مقدار R^2بالا و RMSE و MAE پایینی بدست آمد که نشان دهنده کارایی بالایی این مدل در مرحله آموزش می‌باشد. ولی برای مرحله تست مقدار R^2 پایین و RMSE و MAE بالایی بدست آمد که نشان می‌دهد این مدل کارایی خوبی در مرحله تست ندارد.

مقدار R^2 برای مرحله تست ۲۹ درصد نسبت به مرحله آموزش کاهش پیدا کرد، مقدار RMSE برای مرحله تست ۳۶۹ درصد نسبت به مرحله آموزش افزایش پیدا کرد و MAE برای مرحله تست ۳۰۳ درصد نسبت به مرحله آموزش افزایش پیدا کرد. که این نشان دهنده این است که مدل ماشین بردار پشتیبان کارایی خوبی برای پیش‌بینی مرحله تست ندارد.

و همچنین R^2، RMSE و MAE به ترتیب برای مراحل آموزش و تست گوگرد برابر با ۰/۹۹ ، ۱ و ۰/۷۷۳۱۸ و ۰/۴۴ ، ۵/۶۵۰۱ و ۵/۰۳۱۱ می‌باشد. که مقدار R^2 برای مرحله تست ۵۵ درصد نسبت به مرحله آموزش کاهش پیدا کرد، مقدار RMSE برای مرحله تست ۴۶۵ درصد نسبت به مرحله آموزش افزایش پیدا کرد و MAE برای مرحله تست ۵۵۰ درصد نسبت به مرحله آموزش افزایش پیدا کرد. که این نشان دهنده این است که مدل ماشین بردار پشتیبان کارایی خوبی برای پیش بینی مرحله تست ندارد.

جدول ۴- ۷- نتایج حاصل از اجرای ماشین بردار پشتیبان برای تخمین ازت و گوگرد خاک

عنصر	تابع کرنل	مرحله محاسباتی	ضریب تبیین (R^2)	RMSE	MAE
ازت	RBF	آموزش	۰/۹۹	۰/۰۰۷۴	۰/۰۰۵۷
		تست	۰/۷۰	۰/۰۳۴۷	۰/۰۲۳
گوگرد		آموزش	۰/۹۹	۱	۰/۷۷۳۱۸
		تست	۰/۴۴	۵/۶۵۰۱	۵/۰۳۱۱

در شکل‌های (۴-۷) الی (۴-۱۰) پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای ازت و گوگرد خاک برای مدل ماشین بردار پشتیبان آورده شده است.

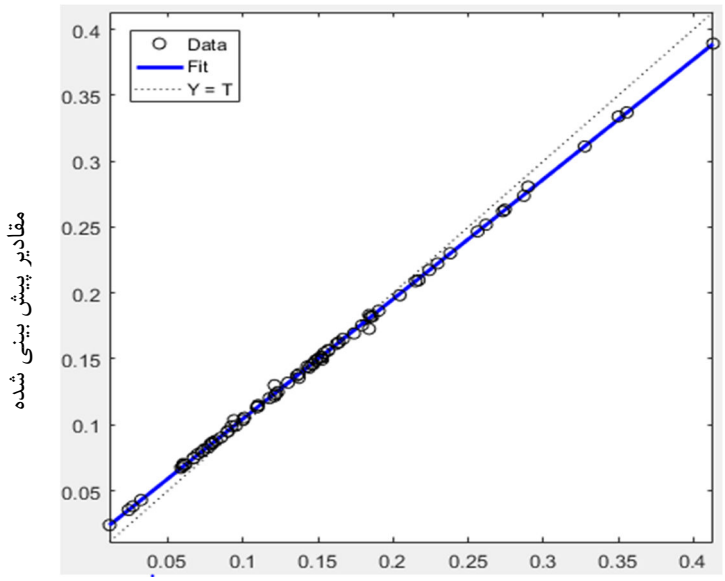

شکل۴- ۷- پراکنش داده های اندازه گیری شده و پیش بینی شده برای مرحله آموزش مدل ماشین بردار پشتیبان ازت خاک

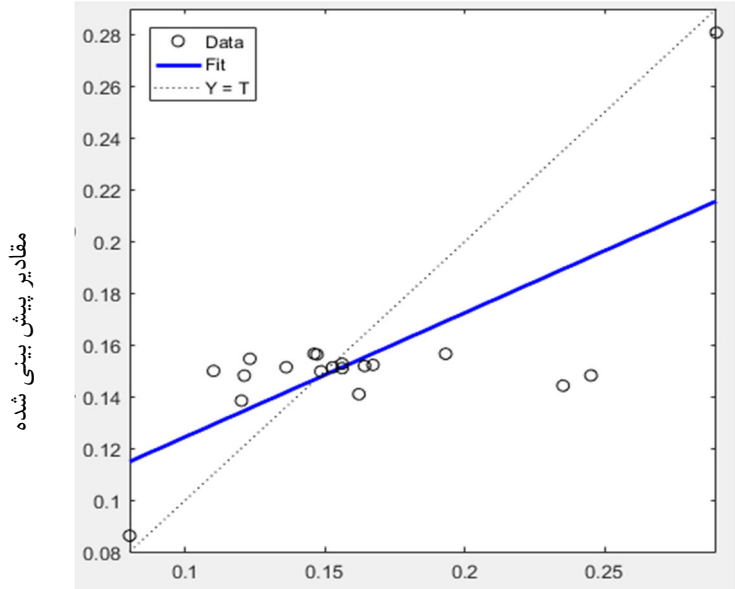

شکل ۴- ۸- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله تست مدل ماشین بردار پشتیبان ازت خاک

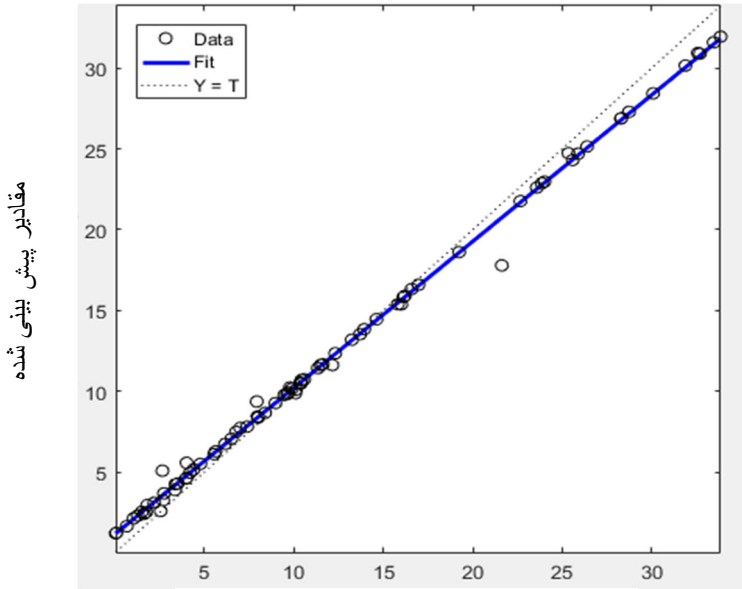

شکل۴- ۹- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل ماشین بردار پشتیبان گوگرد خاک

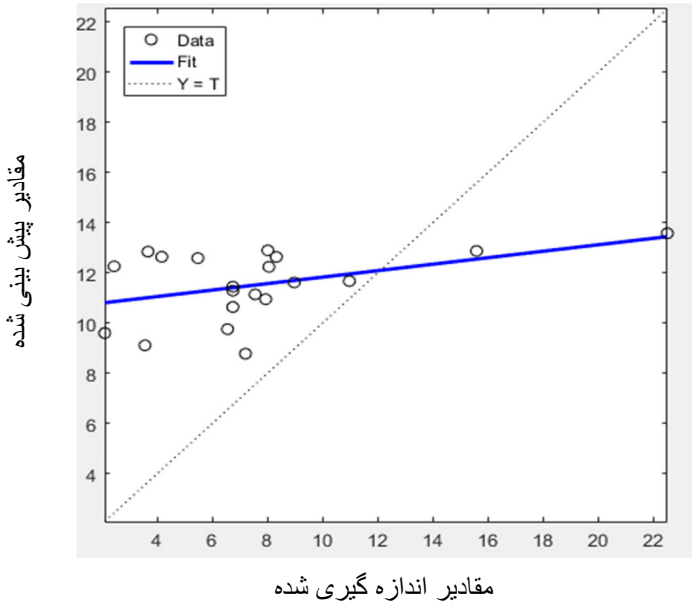

شکل۴- ۱۰- پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله تست مدل ماشین بردار پشتیبان گوگرد خاک

۴-۸- اجرای مدل رگرسیون خطی چند متغیره

در پژوهش‌های مربوط به کشاورزی از مدل رگرسیون خطی استفاده بسیاری می‌شود به همین دلیل در این تحقیق از مدل رگرسیون برای مقایسه با دو مدل شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شد.

برای تعیین رگرسیون چند متغییره پارامترهای مورد مطالعه، مقایسه آن با شبکه عصبی مصنوعی و ماشین بردار پشتیبان به روش مشابه به دو دسته ۸۰٪ و ۲۰٪ به ترتیب به دیتای آموزش و تست تفکیک شدند. رابطه رگرسیونی مربوطه را با استفاده از داده‌های آموزش تعیین کرده که بصورت روابط (۴-۱) و (۴-۲) برای ازت و گوگرد خاک می‌باشد. سپس داده‌ها در مرحله تست یا استفاده از روابط به دست آمده در مرحله آموزش مورد بررسی قرار گرفتند. برای اجرای مدل از پارامترهای PH ، EC، بافت و موادآلی به عنوان متغیرهای مستقل و از پارامترهای ازت و گوگرد خاک به عنوان پارامترهای وابسته استفاده

گردیـد. بـرای تعیـین دقـت توابـع از پارامترهـای آمـاری ضـریب تبیـین (R^2)، میـانگین مجـذور ریشه خطا (RMSE) و میانگین خطای مطلق (MAE) استفاده گردید.

ازت =۰/۲۷۱- ۰/۰۴۹ (PH) + ۰/۰۱۵ (EC) + ۰/۰۰۲(Sand) +۰/۰۰۱ (Clay) +۰/۰۰۲ (Silt)

+۰/۰۵۴ (OC) R^2=۰/۵۵

(۱-۴)

گوگرد=-۴۱/۰۰۸+ ۱/۴۸۳ (PH) + ۱۱/۸۱۵ (EC) + ۰/۲۹۱(Sand) +۰/۳۲۰(Clay) +۰/۲۸۴(Silt)

+ ۰/۰۴۳ (OC) R^2=۰/۶۵

(۲-۴)

در جـدول (۴-۸) نتـایج حاصـل از اجـرای مـدل رگرسـیونی بـرای ازت و گـوگرد خـاک آورده شـده اسـت. همـانطور کـه مشـاهده مـی‌شـود مـدل رگرسـیون بـا R^2، RMSE و MAE ۰/۴۱، ۰/۰۶۳ و ۰/۰۴۸ بـرای داده هـای تسـت ازت خـاک و ۰/۲۸، ۵/۰۹۵ و ۳/۹۵۱ بـرای داده‌هـای تسـت گـوگرد خـاک را تخمـین زده اسـت.که حـاکی از دقـت پـایین و خطـای بـالا در تخمـین ازت و گـوگرد خـاک مـی‌باشـد. در شـکل‌هـای (۵-۱۱) الـی (۴-۱۴) پـراکنش داده‌هـای انـدازه‌گیـری شـده و پـیش‌بینـی شـده بـرای ازت و گـوگرد خـاک بـرای مـدل رگرسـیون خطـی چنـد متغییـره آورده شده است.

جدول ۴- ۸- نتایج حاصل از اجرای مدل رگرسیونی خطی چند متغییره برای تخمین ازت و گوگرد خاک

عنصر	مرحله محاسباتی	ضریب تبیین (R^2)	RMSE	MAE
ازت	آموزش	۰/۵۵	۰/۰۶۷	۰ /۰۵۰
	تست	۰/۴۱	۰/۰۶۳	۰/۰۴۸
گوگرد	آموزش	۰/۶۵	۷/۲۵۵	۵/۸۴۵
	تست	۰/۲۸	۵/۰۹۵	۳/۹۵۱

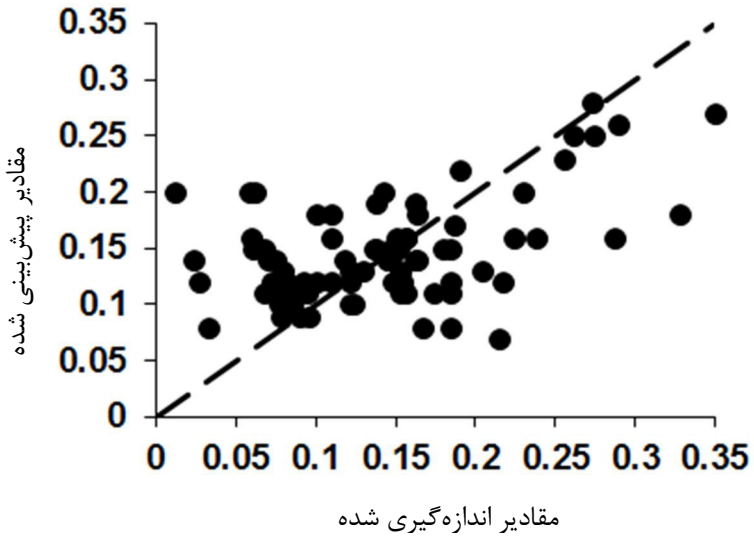

شکل ۴- ۱۱- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون ازت خاک

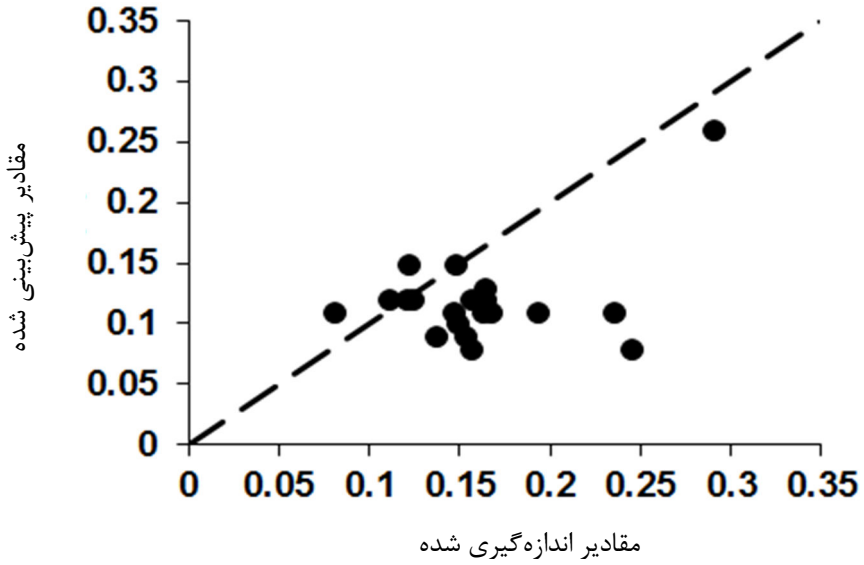

شکل ۴-۱۲- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله تست مدل رگرسیون ازت خاک

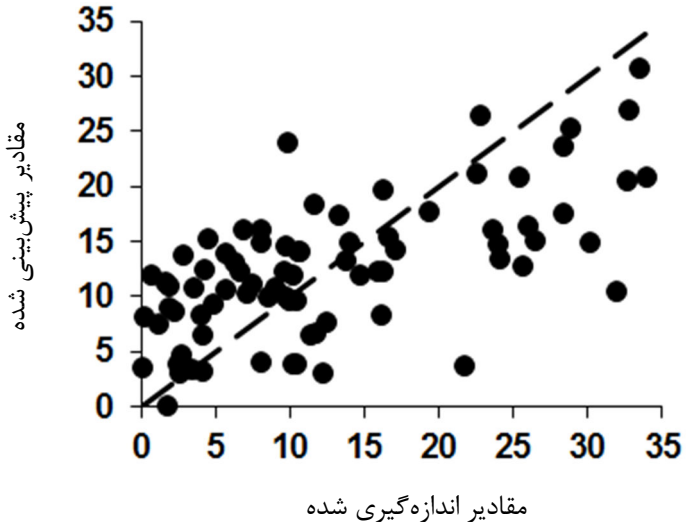

شکل ۴-۱۳- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون گوگرد خاک

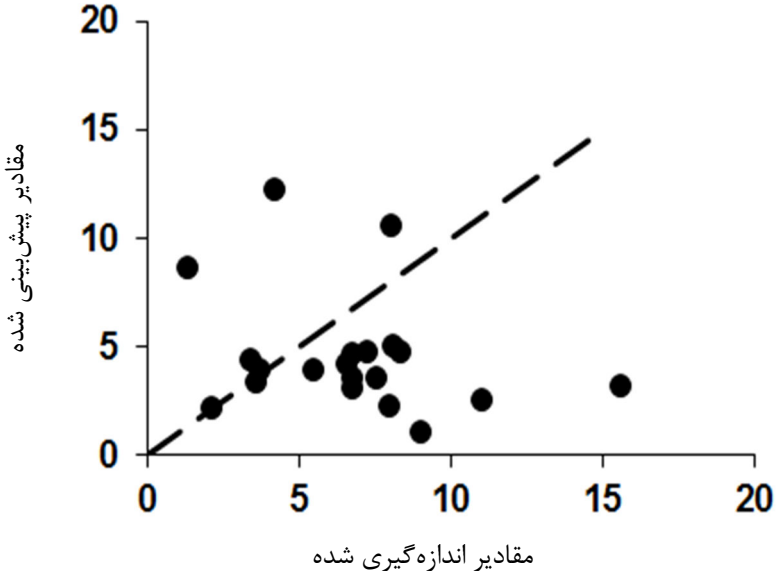

شکل ۴-۱۴- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله تست مدل رگرسیون گوگرد خاک

۴-۹- مقایسه مدل شبکه عصبی مصنوعی **(MLP)** ، مدل ماشین بردار پشتیبان **(SVM)** و مدل رگرسیون خطی چند متغیره

نتایج حاصل از شبکه عصبی مصنوعی، ماشین بردار پشتیبان و رگرسیون خطی چند متغیره برای تخمین ازت و گوگرد خاک در جدول (۴-۹) و (۴-۱۰) آورده شده است. نتایج این بررسی نشان می‌دهد مدل ماشین بردار پشتیبان برای ازت خاک به ترتیب با R^2، RMSE و MAE ۰/۹۹، ۰/۰۰۷۴ و ۰/۰۰۵۷ برای مرحله آموزش قابلیت بالایی را در تخمین ازت خاک دارد و نسبت به روش شبکه عصبی مصنوعی که به ترتیب با R^2، RMSE و MAE ۰/۸۶، ۰/۰۴۰ و ۰/۰۳۲ برای داده‌های آموزش را که تخمین زده است و همچنین نسبت به رگرسیون خطی چند متغیره که به ترتیب با R^2، RMSE و MAE ۰/۵۵ ، ۰/۰۶۷ و ۰/۰۵۰ برای داده‌ای آموزش را تخمین زده است بالاترین دقت وکمترین میزان خطا (بیشترین ضریب تبیین و کمترین مقادیر RMSE و MAE) را در تخمین ازت خاک دارد.

و همچنین مدل ماشین بردار پشتیبان برای گوگردخاک به ترتیب با R^2، RMSE و MAE ۰/۹۹، ۱ و ۰/۷۷۳۱۸برای مرحله آموزش قابلیت بالایی را در تخمین گوگرد خاک دارد و نسبت به روش شبکه عصبی مصنوعی که به ترتیب با R^2، RMSE و MAE ۰/۸۸، ۴/۵۴۱ و ۳/۱۴۷ برای داده‌های آموزش را که تخمین زده است و همچنین نسبت به رگرسیون خطی چند متغیره که به ترتیب با R^2، RMSE و MAE ۰/۶۵ ، ۷/۲۵۵ و ۵/۸۴۵ برای داده‌های آموزش را تخمین زده است بالاتریت دقت وکمترین میزان خطا (بیشترین ضریب تبیین و کمترین مقادیر RMSE و MAE) را در تخمین گوگرد خاک دارد.

اما مدل ماشین بردار پشتیبان برای گوگرد خاک به ترتیب با R^2، RMSE و MAE ۰/۴۴، ۵/۶۵۰۱ و ۵/۰۳۱ برای مرحله تست قابلیت بالایی را در تخمین گوگرد خاک دارد و نسبت به روش شبکه عصبی مصنوعی که به ترتیب با R^2، RMSE و MAE ۰/۴۳، ۱۰/۰۰۷

و ۶/۶۸۹ بـرای داده‌هـای تسـت را کـه تخمـین زده اسـت بـالاترین دقـت وکمتـرین میـزان خطـا (بیشترین ضریب تبیین و کمترین مقادیر RMSE و MAE) را در تخمین ازت خاک دارد.

ولی نسـبت بـه رگرسـیون خطـی چنـد متغیـره کـه بـه ترتیـب بـا R^2، RMSE و MAE ۰/۲۸، ۵/۰۹۵ و ۳/۹۵۱ بـرای داده‌هـای تسـت را تخمـین زده اسـت بـالاترین دقـت را دارد امـا میـزان خطـا بیشتری(بیشـترین ضـریب تبیـین و بیشـترین مقـادیر RMSE و MAE) را در تخمـین گوگرد خاک دارد.

جدول ۴- ۹- نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و رگرسیون خطی چند متغیره برای تخمین ازت خاک

مراحل محاسباتی	پارامتر	شبکه عصبی مصنوعی	ماشین بردار پشتیبان	رگرسیون
آموزش	R^2	۰/۸۶	۰/۹۹	۰/۵۵
	RMSE	۰/۰۴۰	۰/۰۰۷۴	۰/۰۶۷
	MAE	۰/۰۳۲	۰/۰۰۵۷	۰/۰۵۰
تست	R^2	۰/۶۰	۰/۷۰	۰/۴۱
	RMSE	۰/۰۵۷	۰/۰۳۴۷	۰/۰۶۳
	MAE	۰/۰۴۲	۰/۰۲۳	۰/۰۴۸

جدول ۴- ۱۰- نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی، مدل ماشین بردار پشتیبان و رگرسیون خطی چند متغیره برای تخمین گوگرد خاک

مرحله محاسباتی	پارامتر	شبکه عصبی مصنوعی	ماشین بردار پشتیبان	رگرسیون
آموزش	R^2	۰/۸۸	۰/۹۹	۰/۶۵
	RMSE	۴/۵۴۱	۱	۷/۲۵۵
	MAE	۳/۱۴۷	۰/۷۷۳۱۸	۵/۸۴۵
تست	R^2	۰/۴۳	۰/۴۴	۰/۲۸
	RMSE	۱۰/۰۰۷	۵/۶۵۰۱	۵/۰۹۵
	MAE	۶/۶۸۹	۵/۰۳۱۱	۳/۹۵۱

فصل پنجم

نتیجه گیری و پیشنهادها

۵-۱- نتیجه‌گیری

نتایج حاصل از همبستگی بین پارامترهای خاک و عناصر پیش‌بینی شونده برای اهمیت متغیرها در هر دو مدل مورد استفاده نشان داد که کربن آلی بیشترین مشارکت را در پیش‌بینی نیتروژن و شوری خاک بیشترین مشارکت را در پیش‌بینی گوگرد در منطقه مورد مطالعه داراست و سیلت و کربن آلی برای گوگرد در درجه دوم اهمیت قرار دارند .هر چند وجود همبستگی بین برخی ویژگی‌های زودیافت خاک، قابلیت استفاده از آن‌ها را به عنوان متغیرهای موثر در پیش‌بینی عناصر مذکور خاک به اثبات می‌رساند، اما در بهترین حالت، این نکته را باید در نظر گرفت که عواملی دیگر نیز در فرآیند تشکیل و تکامل خاک نقش دارند، از این‌رو نمی‌توان انتظار داشت که بتوان همه تغییرات را از این طریق پیش‌بینی نمود.

نتایج تحقیقات نشان می‌دهد که در بیشتر نقاط منطقه مورد مطالعه عنصر نیتروژن در حد متوسط می‌باشد. همچنین میزان کربن آلی و گوگرد در اکثر نقاط در حد استاندارد بوده و با توجه به اینکه عناصر یاد شده تاثیر بسزایی در رشد و نمو و همچنین کیفیت برنج را دارا می‌باشند، لذا در خصوص مصرف درست این عناصر در خاک باید تمهیدات لازم اندیشیده گردد.

همچنین استفاده از مدل‌های ANN و SVM ، سبب افزایش دقت، سرعت و سهولت دستیابی عناصر پیش‌بینی شده است.

بررسی آماری دو روش ANN و SVM نشان داد که مدل ماشین بردار پشتیبان با بهترین کارایی، بیشترین ضریب تبیین و کمترین میزان خطا نسبت به شبکه عصبی مصنوعی، عمل نموده است.

با توجه به این که استفاده از مدل‌های ANN و SVM کمک شایانی به مدیریت هزینه در بحث پیش‌بینی عناصر می‌نماید و باتوجه به پر هزینه بودن انجام آزمایشات فراوان در

زمینه حاصلخیزی پیشنهاد می‌گردد پیش‌بینی با استفاده از این نرم افزار بیش از پیش مورد توجه قرار گیرد.

در نهایت می‌توان نتیجه گرفت که گسترش ابزارهایی مناسب برای تخمین خصوصیات خاک به ویژه در سیستم‌های کشاورزی به دلیل ناهمگونی نسبتا بالا ناشی از مدیریت و وجود روابط غیر خطی امری ضروری است.

۵-۲- پیشنهادها

- توصیه می‌شود تحقیقات آتی با جمع‌آوری مجموعه داده‌های بزرگتر با دامنه پارامترهای گسترده تر و مناطق جغرافیایی متفاوت‌تر انجام شوند زیرا شبکه‌های عصبی مصنوعی یک عمل درون یابی در محدوده تغییرات پارامترهای ورودی را انجام می‌دهند.

- روش ماشین بردار ارائه شده در این تحقیق علاوه بر سهولت در استفاده، دارای سرعت و دقت بهتری نسبت به روش شبکه‌های عصبی مصنوعی می‌باشد. توصیه می‌شود تحقیقات بعدی بیشتر بر روی این روش و دیگر روش‌های نوظهور آموزش ماشین بردار پشتیبان صورت گیرد.

- روش ماشین بردار پشتیبان را می‌توان با روش ها و الگوریتم‌های جدیدی ترکیب کرد که این کار باعث کارایی بهتر این روش می‌شود و همچنین اهمیت و تاثیر پارامترهای ورودی با روشی جدید تعیین می‌شود.

- توصیه می‌شود در تحقیقات بعدی از فاکتورهای آماری بیشتری نظیر خطای استاندارد (SE) و برتری نسبی(RI) برای تعیین دقت مدل و میزان خطای اعداد پیش‌بینی شده نسبت به اعداد اندازه‌گیری شده در تخمین ازت و گوگرد خاک استفاده شود.

- توصیه می‌شود برای تخمین ازت و گوگرد خاک و بررسی نتایج آن‌ها از مدل الگوریتم ژنتیک (GA)، برنامه ریزی ژن(EPG) و نروفازی (ANFIS) استفاده شود.

منابع

احمـــدی، ک. قلـــی زاده، ح. عبـــاد زاه، ح. حســـین پـــور، ر. عبدشـــاه، ه. کاظمیـــان، آ. و رفیعـــی، م. (۱۳۹۵-۱۳۹۴)." آمار نامه کشاورزی ".

اسـلام زاد، ط و خلـد بـرین، ب. (۱۳۷۰). " نقـش تنظـیم کننـده‌هـای رشـد گیـاهی بـر ایجـاد مقاومـت بـه شوری در گیاه جو (Hordeum) و لوبیا (Phaseolus vulgaris) " . مجله زیتون، ۱۲: ۲۰.

بازوبنـــدی، ا. قربـــانی، ه. امـــامقلی‌زاده، ص و شـــعیبی نوبریـــان، م.ر. (۱۳۹۶) " پـــیش‌بینـــی ظرفیـــت تبـــادل کـاتیونی خـاک‌هـای اسـتان گـیلان بـا اسـتفاده از مـدل‌هـای هوشـمند" . نشـریه علمـی کشـاورزی، ۳۱(۳): ۳۹۱-۳۷۵.

بازوبنـدی، ا. (۱۳۹۴). پایانامـه ارشـد:" پـیش بینـی فلـزات سـنگین و CEC خـاک بـا اسـتفاده از خصوصـیات خاک به کمک مدل‌های هوشمند". دانشکده کشاورزی و منابع طبیعی، دانشگاه صنعتی شاهرود.

بازوبنـــدی، ا. صـــابری، ا. قربـــانی، ه و امـــامقلی زاده، ص. (۱۳۹۳). "پـــیش بینـــی فســـفر خـــاک بـــا اســـتفاده از خصوصـیات خـاک بـه کمـک شـبکه ی عصـبی". اولـین کنفـرانس ملـی جغرافیـا، گردشـگری، منـابع طبیعـی و توسعه پایدار، تهران.

برزگـــر، ع. (۱۳۸۷). "خـــاک هـــای شـــور و ســـدیمی(شـــناخت و بهـــره وری)" ، انتشـــارات دانشـــگاه شـــهید چمران.

بســـالت پـــور، ع.ا. شـــیرانی، ح. و اســـفندیارپور، ع. (۱۳۹۴)." مدلســـازی پایـــداری خاکدانـــه هـــا بـــا اســـتفاده از ماشین های بـردار پشـتیبان و رگرسیون چند متغیره خطی". مجله آب و خاک. ۲۹(۲): ۴۰۶-۴۱۷.

جعفـــــری، م. و ســـــرمدیان، ف. (۱۳۸۲). ".مبـــــانی خاکشناســـــی و ردهبنـــــدی خـــــاک". انتشـــــارات دانشگاه تهران، چاپ اول.

خـداوردی لـو، ح. فتحـی، پ. و همـایی، م. (۱۳۸۳). " تخمـین هوشـمند منحنـی رطـوبتی خـاک بـا اسـتفاده از شبکه عصبی مصنوعی". دومین کنفرانس ملی دانشجویی منابع آب و خاک، دانشگاه شیراز.

دماونـــدی، ع. مســـیح آبـــادی، م. و تکاســـی، م. (۱۳۸۴). "ارزیـــابی کیفـــی تناســـب اراضـــی بـــر روی محصـــول چغندرقند در منطقه خدابنده استان زنجان". خلاصه مقالات نهمین کنگره علوم خاک، تهران.

رشـیدی، ن. و کریمیـان، ن. ع. (۱۳۷۸). "تـأثیر گـوگرد و روی بـر رشـد و ترکیـب شـیمیایی ذرت در یـک خاک آهکی". چکیده مقالت ششمین کنگره علوم خاک ایران، مشهد، ایران.

صمدی، ع. (۱۳۹۲). پایانامه ارشد: "پهنه بندی عناصر غذایی با استفاده از شبکه عصبی مصنوعی و زمین آمار در دشت ارومیه". دانشکده کشاورزی و منابع طبیعی، دانشگاه صنعتی شاهرود.

علیجانپورشلمانی، ع. (۱۳۹۰). " تخمین پایداری خاکدانه در خاک های جنگلی استان گیلان بوسیله شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی" نشریه دانش آب و خاک، ۲۱(۳): ۱۵۳-۱۶۲.

قربانی، ه. روحانی، ع. و حافظی مقدس، ن. (۱۳۹۲). " ارزیابی قابلیت مدل شبکه عصبی مصنوعی LVQ4a2در پیش بینی الگوی توزیع مکانی کادمیم در خاک" نشریه آب و خاک(علوم وصنایع کشاورزی)، ۲۷(۱)، ۱۰۲-۹۰.

کاشانی، ح. امامقلی‌زاده، ص. قربانی، ه. و هاشمی، س.ع.ا. (۱۳۹۲). "برآورد نفوذپذیری خاک توسط شبکه عصبی مصنوعی و رگرسیون خطی در اراضی کشاورزی و بکر" نشریه پژوهش‌های فرسایش محیطی، ۳(۱)، ۳۴-۱۹.

کیا، م. (۱۳۸۹). "شبکه‌های عصبی مصنوعی در MATLAB ". انتشارات کیان رایانه سبز. ص ۲۳۲ ، تهران.

مزدک فتاحی (۱۳۹۳)،" مروری بر ماشین‌های بردار پشتیبان"، دانشکده فنی مهندسی رازی.

معماریان فر، م. و بیگی هرچگانی، ح . (۱۳۸۸). "مقایسه مدل های شبکه عصبی مصنوعی وتوابع انتقالی رگرسیونی برای پیش بینی ظرفیت تبادل کاتیونی خاک های استان چهارمحال وبختیاری". نشریه آب و خاک،۲۳(۴)، ۹۰- ۹۹.

ملکوتی، م. کاووسی، م. (۱۳۸۳). "تغذیه متعادل گیاه برنج". انتشارات سنا.

منهاج، م. و سیفی پور، ن. (۱۳۷۷). "کاربرد هوش محاسباتی در کنترل". جلد دوم، انتشارات دانشگاه امیرکبیر، تهران، ص ۲۳۶.

منهاج، م. (۱۳۸۱). "مبانی شبکه عصبی" جلد اول، انتشارات دانشگاه امیرکبیر، تهران، ص ۵۰۲.

منهاج، م.ب. (۱۳۸۱). "شبکه‌های عصبی مصنوعی "انتشارات دانشگاه صنعتی امیر کبیر."

مهربانیان، م، تقی زاده مهرجردی، ر. ا. و دهقانی، ف، (۱۳۸۹). " بررسی کارایی توابع انتقالی جهت تخمین ظرفیت تبادل کاتیونی خاک های آهکی و گچی استان یزد". مجله پژوهش های حفاظت آب و خاک، ۱۷ (۱) ۱۱۳-۱۲۷.

موسی زاده مجرد، ر. ه. و سپاسخواه، ع. (۱۳۸۷). "پیش بینی منحنی مشخصه آب خاک با استفاده از مدل شبکه عصبی مصنوعی". دومین همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.

نظریات، ث. هودجی، م. و بسالت پور، ع. (۱۳۹۶). " مدلسازی توزیع سرب با استفاده از ماشین های بردار پشتیبان۱در خاک سطحی زمین های حاشیه بزرگراه دزفول-اهواز"نشریه پژوهش های خاک علوم خاک و آب۳۱(۱)، ۱۴۳-۱۵۳.

Anderson J. A. (1995). Introduction to Neural Networks, Cambridge University Press).

Ayres, A. D., and Westcot D.W. (1985). Water quality for agriculture. F.A.O. Irrigation and Drainage bulletin, University of California.

Behzad M..Asghari K..Eazi M.and Pallhang M.(2009) Generalization performance of support vector machines and neural networks in runoff modeling. Expert Systems with Applications, 36:7624-7629.

Bosun SZ and Qiguo Z, (2003). Evaluation of spatial and temporal changes of soil quality based on geostatistical analysis in the hill region of subtropical, China.Geoderma 115: 85-99.

Botsis D. Latinopoulos P. and Diamantaras K.(2011). Rainfall-Runoff Moeling Using Suport Vector Regression and Artificial Neural Networks. 12th International Conference on Environmental Science and Technology, CEST2011- Rhodes, Greece.

Bouma J. (1989) Using soil survey data for quantitative land evaluation. Soil Sci, 9, 177–213 .

Bouyoucos G.J. (1962). Hydrometer method improved for making particle size analysis of soil. Agron. Journal. 54(5): 464-465.

Bremner J.M. and Mulvaney R.L. (1978). Urease activity in soils. Soil Enzymes, Academic Press, New York, NY,USA, pp.149-187.

Bybordi M. (2001). Soil Physics, 6th Edition, Tehran University Publications, 1672: 567-574.

Bishop,C.M. and Tipping M.E. (2000). Variational relevance vector machines. In ncertainty in artificial intelligence, Morgan Kaufmann Publishers Inc, 46-53

Chang DH and Islam S, (2000). Estimation of soil physical properties using remote sensing and artificial neural network. Remote Sensing of Environment 74: 534–544.

Cortes C. and Vapnik V.N. (1995) Support vectors networks, Mashin Learning 20: 1-25.

Doaei M. Shabanpour-e-Shahrestani M. and Bagheri F. (2005). Modellin of Saturated Hydraulic conductivity of Gilan Province involving Artificial Neural Networks, The Agricultural Science Research Report, Faculty of Agriculture, Gilan University.

Drummond S.T. Sudduth K.A. Joshi A. Birrell S.J. Kitchen N.R. (2003). Statistical and neural methods for site-specific yield prediction. Transactions of the American Society of Agricultural and Biological Engineers 46: 5–14.

Eriko I. Kenji O. Yoichi M.I. Makoto A. (2008). A neural network approach to simple prediction of soil nitr ification potential: A case study in Japanese temperate forests , ecological m o delling. 219: 200-212.

Eriko I. Kenji O. Yoichi M. I. Makoto A. (2008).A neural network approach to simple prediction of soil nitrification potential: A case study in Japanese temperate forests**.** Ecological Modelling journal,219(1-2): 200-211.

Fatemi A. Sarikhani R. Teshnelab M. (2002) Application of Artificial Neural Network to Predict Landslid- A case study from Talesh- GilanT North of Iran,Proceding of 9th congress of the International Association for Engineering Geology and the Envaironment,Durban.

Folk R. L. (1966) A Review of Grain Size Parameters, Sedimentology, 6: 73-93.

Givi J. Prasherb S. O. and Patel R. M. (2004) Evaluation of pedotransfer functions in predicting the soil water contents at field capacity and wilting point. Agri. Water Manag, 70: 83–96.

Gutierrez P.A. Lopez-Granados F. Pena-Barragan J.M. Jurado-Exposito M. Gomez-Casero M.T and Hervas-Martinez C. (2008). Mapping sunflower yield as affected by Ridolfia segetum patches and elevation by applying evolutionary product unit neural networks to remote sensed data.computers and electronics in agriculture 60 : 122-132.

Hecht-Neilan R. (1990) Neurocomputing ,Adissin Wesely Publishing Company.

Helmke P. A. and Loeppert R.H. method of soil analysis Poblished by: soil science society of American, Inc. American society of agronomy. Inc. Madison, Washington, USA.

Hitsuda K. M. Yamada and D. Klepker. (2005). Soil and Crop Management: Sulfur requirement of eight crops.

Huang B. Sun W. Zhao Y. Zhu J. Yang R. Zou Z. et al. (2007) Temporal and spatial variability of soil organic matter and total nitrogen in an agricultural ecosystem as affected by farming practices. Geoderma, 139: 336–345.

Ibrahim Ekhmaj A. (2010) Predicting Soil Infiltration Rate Using Artificial Neural Network International Conference on Environmental Engineering and Applications.

Jin Y.Q. and Liu C. (1997). Biomass retrieval from high-dimensional active/passive remote sensing data by using artificial neural networks. International Journal of Remote Sensing 18: 971–979.

Kabata-pendias A. and Pendias H. (1986). Trace element in soil and plants. CRC press, Boca Roton. Florida. USA.

Kaul M. Hill R.L. and Walthall C. (2005) Artificial neural networks for corn and soybean yield prediction. Agriculture system 85: 1-18.

Kennedy J.B. and Neviile A.D. (1964), Basic statistical methods for engineers and scientists, Happer International Edition.

Merdun H. Cinar O. Meral R. and Apan M. (2006) Comparison of artificial neural network and regression perdotransfer functions for prediction of soilmwater retention and saturated hydraulic conductivity Soil and Tillage.

Minasny B. A.B. McBratney and K.L. Bristow. (1999). Comparison of different approaches to the development of pedotransfer functions for water retention curves. Geoderma 93: 225–253.

Minasny B. J. Hopman W.T. Harter S.O. Eching A. Toli and M.A. Denton. (2004). Neural networks prediction of soil hydraulic functions for alluvial soils using multistep outflow data. Soil Sci. Soc. Amer. J. 68: 417– 429.

Minsany B. and Mcbratney A.B. (2002) The Neuro-m method for fitting neural network parametric pedotransfer function . Soil Sci. Soc. Am.J. 66:352-361.

Misra D.T. Oommen A. Agarwal and S.K. Mishra. (2009). Application and Analysis of Support Vector Machine Based Simulation for Runoff and Sediment Yield Bios stems Engineering. 103: 527-535.

Moghadamnia A. M.Ghafari J.Piri D.Han. (2008). Evaporation estimation using support vector machines technique. Engineering and Technology, 33: 14-22.

Mohammadi J. (2002) Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical properties. 17th WCSS. Thailand. Paper No. 221.

Nunnari G. Dorling S. Schlink U. Cawley G. Foxall R. Chatterton T. (2004) Modelling SO2 concentration at a point with statistical approaches. Environmental Modelling& Software 19:887- 905.

Puget P.and Drinkwater L.E. (2001) Short-term dynamics of root- and shoot- drived Carbon from a leguminous green manure. SoilSci.Soc.Am.J.65: 771-779.

Ramesh G.a. Suranjan P.b. David F.c. Albert S.d. (2011) Residual soil nitrate prediction from imagery and non-imagery information using neural network technique ,biyosystems engeering. 110: 20-28.

Rawls W.J. T.J. Gish and D.L. Brakensiek. (1991). Estimating soil water retention from soil physical properties and characteristics. Adv. Soil Sci. 9: 213–234.

Rhoades J. (1996) Electrical conductivity and total dissolved solids.In:Sparks D.L. Page A.L. Helmke P.A. and Loeppert R.H. method of soil analysis Poblished by: soil science society of American, Inc. American society of agronomy. 417-435

Rub G. Kruse R. Schneider M. and Wagnr P. (2009). Using advanced regression models for determining optimal soil heterogeneity indicators . Studies in Classification, Data Analysis, and Knowledege Organization, 463-471.

Shahbazi, A. Zahraei B.and Naseri M. (2012). Seasonal Meteorological Drought Prediction Using Support Vector Machine. Water and Waste, 2: 73-85.

Sharma V. Negi S.C. Rudra R.P. Yang S. (2003) Neural networks for predicting nitrate-nitrogen in drainage water , Agricultural Water Management, 63 : 169-183.

Smith G.N. (1986) Probability and statistics in civil engineering, Collins.

Soil Survey Staff (1996) Soil Survey Laboratory Methods Manual. Soil Survey Investigations Report No. 42, Version 3.0, USDANRCS National Soil Survey Center, Washington, D.C.

Taheri H. and M. Ghafouri. (2012). Comparison between Active Learning Method and Support Vector Machine for Runoff Modeling. Journal of Hydrology and Hydromechanics. 1: 16-32.

Tamari S. Wosten J. H. M. and Ruz-suarez J. C. (1996) Testing an artificial neural network for predicting soil hydraulic conductivity J.Soil Sci. Soc. Am,49:1100-1105.

Theng, B.K.G. Tate K.R. and Sollins P. (1989) Constituents of organic matter in temperate and tropical soils. Publication of the University of Hawaii, 3: 5-32.

Thomas, G.W. (1996) Soil pH and Soil Acidity. In: Sparks, D.L., Ed., Methods of Soil Analysis Part 3: Chemical Methods, SSSA Book Series 5, Soil Science Society of America, Madison, Wisconsin, 475-490.

Torrecilla J.S. Otero L. and Sanz P.D. (2004). A neural network approach for thermal/pressure food processing. Food Engineer 62: 89-95.

V. Sharma S.C. Negi R.P. Rudra S. Yang (2003) Neural networks for predicting nitrate-nitrogen in drainage water, Agricultural Water Management journal, 63(3) 169- 183.

Vakil-Baghmisheh M.T and Pavesic N. (2003). Premature clustering phenomenon and new training algorithms for LVQ. Pattern recognition36: 1901-1921.

Vapnik V. (1995). The Nature of Statistical Learning Theory. Springer-Verlag, New York.

Walkly A. and Black I.A. (1934). An examination of digestion method for determining soil organic matter and proposed modification of the chromic acid titration. Soil Sci. 37: 29-38.

Xiaofei A. Li M. Zheng Li. Sun H. (2014) Eliminating the interference of soil moisture and particle size on predicting soil total nitrogen content using a NIRS-based portable detector , Computers and Electronics in Agriculture. 112: 47-53.

Yoon H. Jun S.C. Hyun Y. Bae G.O. and Lee. K.K. (2011). A Comparative Study of Artificial Neural Networks and Support Vector Machines for Predicting Groundwater Levels in a Coasta Laquifer Journal of Hydrology, 396: 128-138.

Li Y. Liang S. Zhao Y. Li W. Wang Y. (2017). Machine learning for the prediction of L. chinensis carbon, nitrogen and phosphorus contents and understanding of mechanisms underlying grassland degradation Environ Manage journal 1(192): 116-123.

پیوست ۱- نتایج حاصل از اجرای مدل MLP شبکه عصبی مصنوعی با تعداد لایه‌های پنهان مختلف و توابع مختلف در تخمین ازت خاک

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
ازت	سیگموید Sigmoid	۱	آموزش	۰/۷۷	۰/۰۵۱	۰/۰۳۹
			تست	۰/٦٦	۰/۰٤۷	۰/۰۳۵
		۲	آموزش	۰/۷۸	۰/۰۵۰	۰/۰۳۵
			تست	۰/۵۳	۰/۰٤۵	۰/۰۳۰
		۳	آموزش	۰/۸۳	۰/۰٤٤	۰/۰۳٤
			تست	۰/٤۲	۰/۰۵٤	۰/۰٤۰
		٤	آموزش	۰/۷۸	۰/۰۵۰	۰/۰٤۰
			تست	۰/۵۳	۰/۰٤۷	۰/۰۳۸

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
ازت	گوسین Gaussian	۱	آموزش	۰/۷۶	۰/۰۵۲	۰/۰٤۰
			تست	۰/٤۰	۰/۰۵۷	۰/۰٤۳
		۲	آموزش	۰/۸۰	۰/۰٤۸	۰/۰۳۷
			تست	۰/٤۵	۰/۰٦۲	۰/۰٤۵
		۳	آموزش	۰/۸۰	۰/۰٤۸	۰/۰۳٦
			تست	۰/٦۲	۰/۰٤٤	۰/۰۳٦
		٤	آموزش	۰/۸۲	۰/۰٤٦	۰/۰۳۵
			تست	۰/٦۳	۰/۰۵۲	۰/۰٤۲

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
ازت	تانژانت هایپروبولیک Tangent Hyperbolic	۱	آموزش	۰/٦۹	۰/۰۵۷	۰/۰٤۱
			تست	۰/٤۷	۰/۰٤۷	۰/۰۳۱
		۲	آموزش	۰/۷۷	۰/۰۳۷	۰/۰۳۷
			تست	۰/٦۸	۰/۰٤۸	۰/۰۳۵
		۳	آموزش	۰/۸۰	۰/۰٤۷	۰/۰۳۵
			تست	۰/۲۱	۰/۰۵٦	۰/۰٤۵
		٤	آموزش	۰/۷۷	۰/۰۸۸	۰/۰٤۰
			تست	۰/٦۲	۰/۰٤٦	۰/۰۳۵

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
ازت	سکانت هایپروبولیک Secant Hyperbolic	۱	آموزش	۰/۷٦	۰/۰٥۲	۰/۰٤۰
			تست	۰/۳٦	۰/۰٥۹	۰/۰٤٥
		۲	آموزش	۰/۷۹	۰/۰٤۹	۰/۰۳۸
			تست	۰/٥٦	۰/۰٤۹	۰/۰۳۸
		۳	آموزش	۰/۸٦	۰/۰٤۰	۰/۰۳۲
			تست	۰/٦۰	۰/۰٥۷	۰/۰٤۲
		٤	آموزش	۰/۷۰	۰/۰٥۷	۰/۰٤۱
			تست	۰/٤۹	۰/۰٦۰	۰/۰٤۸

پیوست ۲- نتـایج حاصـل از اجـرای مـدل MLP شـبکه عصـبی مصـنوعی بـا تعـداد لایـه‌هـای پنهـان مختلـف و توابع مختلف در تخمین گوگرد خاک

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
گوگرد	سیگموید Sigmoid	۱	آموزش	۰/۸۰	۵/۷۳٤	٤/۳۷٤
			تست	۰/۲۰	٦/۵۳۷	٤/۹۳۷
		۲	آموزش	۰/۸۲	۵/٤۷۱	٤/۰٤۲
			تست	۰/۳۲	۷/٦۱۳	٤/۵۹۲
		۳	آموزش	۰/۸۳	۵/۳۳٦	۳/۸۵۱
			تست	۰/۱۰	۵/۲۸۲	۳/٤۰۹
		٤	آموزش	۰/۸۳	۵/۳۹۳	٤/۰٦۱
			تست	۰/۱۱	۷/۰۷۸	٤/٦٤٤

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
		۱	آموزش	./۷۶	٦/۲٦٦	٤/۸۸۳
			تست	./۱۳	٥/۳٦۳	٤/۳۲۲
		۲	آموزش	./۸۲	٥/٤۸۸	٤/۱٥۲
گوگرد	گوسین		تست	./۳۱	۹/۱۷۰	٦/۱۹۰
	Gaussian	۳	آموزش	./۸۹	٤/٥٤۱	۳/۱٤۷
			تست	./٤۳	۱۰/۰۰۷	٦/٦۸۹
		٤	آموزش	./۸٦	٤/۸۹۷	۳/٦۸۱
			تست	./۱۳	٥/۹۰٥	۳/۲۸٤

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
گوکرد	تانژانت هایپروبولیک	۱	آموزش	۰/۸۳	۵/۴۰۱	۴/۱۴۲
			تست	۰/۲۵	۵/۵۷۴	۴/۱۰۹
		۲	آموزش	۰/۸۵	۵/۰۵۴	۳/۸۲۹
			تست	۰/۲۱	۶/۷۴۶	۴/۱۰۲
	Tangent Hyperbolic	۳	آموزش	۰/۸۴	۵/۲۴۰	۳/۸۴۷
			تست	۰/۱۲	۵/۴۶۴	۳/۲۵۳
		۴	آموزش	۰/۸۳	۵/۳۰۲	۳/۸۶۱
			تست	۰/۱۵	۴/۷۹۹	۳/۴۰۶

عنصر	تابع محرک	تعداد لایه های پنهان	مرحله محاسباتی	R^2	RMSE	MAE
گوگرد	سکانت هایپروبولیک	۱	آموزش	۰/۷۷	٦/۰۸۱	٤/۹۰۲
			تست	۰/۰۷٤	۸/۲٥۹	٦/٥٦٦
		۲	آموزش	۰/۸٥	٥/۱۰۳	۳/۸۹۸
			تست	۰/۳۲	۱۳/۱۰٤	۷/۸۳٤
	Secant Hyperbolic	۳	آموزش	۰/۸۲	٥/٤۲٦	٤/۳٤۰
			تست	۰/۳۳	۱۱/٥٦۰	۷/٦۰۰
		٤	آموزش	۰/۸۸	٤/٤۰۰	۳/۲٦۸
			تست	۰/۰۹۲	۸/۱۱۰	٥/۱۱۰

Abstract

Soil is considered as one of the main factors in the production of agricultural products, and its use must be based on sound and scientific principles to be used in the production of products as a sustainable source. Any mistakes in exploiting it will result in the loss of this valuable resource. Today, the development of a more precise method for agricultural production is one of the ways to minimize the pressure from agricultural operations on the quality of the environment. In recent years, the use of methods such as artificial neural network and backup vector machine have been considered for soil characteristics estimation.

Therefore, in order to estimate the nitrogen and sulfur content of the soil, using artificial neural network model and support vector machine model, the pH, EC, texture and organic carbon properties were used and the results were compared together with the multivariate linear regression model . For estimating and analyzing the parameters, the coefficient of determination (R^2), mean square root error (RMSE) and mean absolute error (MAE) were used.

The results of this study showed a higher efficiency of support vector machine model with R^2 (0.99, 0.99), RMSE (0.0074, 1) and MAE (0.0057, 0 /77318) for N test and Soil sulfur is compared to artificial neural network model and linear multivariate regression model.

Keywords: Nitrogen Estimation, Sulfur Estimation, Artificial Neural Network, support Vector Machine, Multivariate Linear Regression.

Shahrood University of Technology

Faculty of Agriculture

M.Sc. Thesis in Chemistry and fertility

Estimation of Sulfur and Nitrogen of the soil in rice fields of Mazandaran Province using support vector machine (SVM) and artifififual neural network (ANN)

Zinat Roohi-Rise

Supervisor:

Dr Sh. Shahsavani

Advisor:

Dr S. Emamgholizade

September 2018