


رسالة محمد



دانشگاه صنعتی شاهرود

دانشکده کشاورزی

گروه آب و خاک

عنوان:

تخمین رطوبت خاک با استفاده از شبکه عصبی مصنوعی

دانشجو:

میثم ابوالخیریان

اساتید راهنما:

دکتر هادی قربانی

دکتر صمد امامقلی‌زاده

اساتید مشاور:

دکتر عیسی معروف پور

دکتر خلیل اژدری

پایان نامه ارشد جهت اخذ درجه کارشناسی ارشد

ماه و سال انتشار:

تیرماه ۱۳۹۲

دانشگاه صنعتی شاهرود

دانشکده :

گروه :

پایان نامه کارشناسی ارشد آقای میثم ابوالخیریان
تحت عنوان: تخمین رطوبت خاک با استفاده از شبکه عصبی مصنوعی

در تاریخ ۱۳۹۲/۴/۱۶ توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد مهندسی کشاورزی-علوم خاک
مورد ارزیابی و با درجه عالی مورد پذیرش قرار گرفت.

امضاء	امضاء	امضاء	امضاء
	نام و نام خانوادگی : دکتر خلیل اژدری		نام و نام خانوادگی : دکتر هادی قربانی
	نام و نام خانوادگی : دکتر عیسی معروف پور		نام و نام خانوادگی : دکتر صمد امامقلی زاده

امضاء	امضاء	امضاء	امضاء
	نام و نام خانوادگی :		نام و نام خانوادگی : دکتر شاهین شاهپوری
	دکتر مسعود حکیمی تبار		نام و نام خانوادگی : دکتر علی عباسپور
			نام و نام خانوادگی :
			نام و نام خانوادگی :

تشکر و قدردانی

سپاس بی کران پروردگار یکتا را که هستی مان بخشید و به طریق علم و دانش رهنمونمان شد و به همنشینی رهروان علم و دانش مفتخرمان نمود و خوشه چینی از علم و معرفت را روزیمان ساخت. با خضوع و افتادگی تمام بر خود لازم می‌دانم مراتب سپاس و قدردانی صمیمانه خویش را تقدیم به همه کسانی کنم که طی این مدت مرا یاری نموده اند.

از پدر و مادر عزیزم به پاس تعبیر عظیم و انسانی شان از کلمه ایثار و از خودگذشتگی، به پاس عاطفه سرشار و گرمای امید بخش وجودشان که در این سردترین روزگاران بهترین پشتیبان است. به پاس قلب‌های بزرگشان که فریاد رس است و به پاس محبت‌های بی دریغشان که هرگز فروکش نمی‌کند. از اساتید راهنمای بزرگوام، آقایان دکتر هادی قربانی و دکتر صمد امامقلی زاده، به خاطر تمام راهنمایی‌های علمی‌شان در طی مراحل انجام و تدوین پایان نامه نهایت تشکر و امتنان را دارم. چرا که بدون راهنمایی‌های ایشان تامین این پایان نامه بسیار مشکل می‌نمود. از اساتید مشاور گرانقدر و دلسوز آقایان دکتر خلیل اژدری و دکتر عیسی معروف‌پور به خاطر تمام راهنمایی‌ها و مساعدت‌های بی دریغ و ارزشمندشان، کمال تشکر و سپاسگزاری را دارم.

از اساتید و کارشناسان گروه آب و خاک، آقایان دکتر نادری، دکتر شاهسونی، دکتر عباس پور، و مهندس شاکری، و همچنین از دوست عزیزم مهندس کاشی تشکر و قدردانی می‌نمایم.

میثم ابوالخیریان

تیرماه ۹۲

تعهد نامه

اینجانب میثم ابوالخیریان دانشجوی دوره کارشناسی ارشد رشته مهندسی کشاورزی- علوم خاک دانشکده کشاورزی دانشگاه صنعتی شاهرود نویسنده پایان نامه " تخمین رطوبت خاک با استفاده از شبکه عصبی مصنوعی " تحت راهنمایی دکتر هادی قربانی و دکتر صمد امامقلی زاده، متعهد می شوم.

- 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 می باشد 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 بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- 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 ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد . 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 نمی باشد.

* متن این صفحه نیز باید در ابتدای نسخه های تکثیر شده پایان نامه وجود داشته باشد

لیست مقالات مستخرج از پایان نامه

۱. ابوالخیریان م، امامقلی زاده ص، قربانی ه، معروف پور ع و اژدری خ، (۱۳۹۲)، "مقایسه برآورد تغییرات رطوبت حجمی خاک با استفاده از شبکه عصبی مصنوعی و TDR"، دومین کنفرانس بین‌المللی مدلسازی گیاه، آب، خاک و هوا، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان

۲. ابوالخیریان م، امامقلی زاده ص، قربانی ه، معروف پور ع و اژدری خ، (۱۳۹۲)، "تخمین زمانی تغییرات درصد رطوبت حجمی خاک با استفاده از شبکه عصبی مصنوعی"، دوازدهمین همایش ملی آبیاری و کاهش تبخیر، دانشگاه شهید باهنر، کرمان

چکیده

اندازه‌گیری رطوبت حجمی خاک و آب قابل دسترس برای گیاهان در رشته‌های مختلف مانند خاکشناسی، هیدرولوژی و مهندسی آب بسیار مهم است. بنابراین بررسی متعدد رطوبت خاک و میزان قابل استفاده آن برای گیاه از مهم‌ترین موضوعات در علم رابطه آب، خاک و گیاه است. برای تعیین رطوبت از روش‌های مختلفی مانند روش مستقیم (روش وزنی) و روش‌های غیر مستقیم مانند استفاده از دستگاه TDR و شبکه‌های هوش مصنوعی مانند شبکه عصبی، فازی، فازی-عصبی، الگوریتم ژنتیک می‌توان بهره جست. در سال‌های اخیر استفاده از روش‌های غیر مستقیم مانند شبکه عصبی مصنوعی برای برآورد ویژگی‌های خاک مورد توجه قرار گرفته است. لذا در این تحقیق به منظور تخمین رطوبت حجمی خاک با استفاده از مدل شبکه عصبی مصنوعی از ویژگی‌های وزن مخصوص ظاهری، تخلخل، مواد آلی و زمان در سه نوع خاک با بافت سبک، متوسط و سنگین استفاده گردید و نتایج حاصل با مدل رگرسیون خطی چند متغیره و روش TDR مقایسه گردید. همچنین تغییرات زمانی رطوبت حجمی در هر سه نوع خاک برآورد شد و برای ارزیابی و تجزیه و تحلیل آماری از پارامترهای ضریب تبیین (R^2 , R squared)، میانگین خطای مطلق (Mean Absolute Error, MAE) میانگین مجذور ریشه خطا (Root Mean Squared Error, RMSE) استفاده گردید. نتایج حاصل از این تحقیق کارایی بالاتر مدل شبکه عصبی مصنوعی را با R^2 (۰/۹۷، ۰/۹۹، ۰/۹۷)، RMSE (۰/۷۸۵)، MAE (۰/۴۰۱، ۰/۸۶۰) و (۰/۵۵۱، ۰/۳۱۲، ۰/۶۸۵) به ترتیب برای مرحله صحت یابی بافت سبک، متوسط و سنگین نسبت به روش رگرسیون چند متغیره خطی و روش TDR نشان می‌دهد.

کلمات کلیدی: تغییرات زمانی، رطوبت حجمی خاک، رگرسیون خطی چند متغیره، شبکه عصبی مصنوعی.

فهرست مطالب

۱.....	فصل اول کلیات.....
۲.....	۱-۱- مقدمه.....
۳.....	۲-۱- ضرورت تحقیق.....
۴.....	۳-۱- اهداف.....
۵.....	۴-۱- روش تحقیق.....
۶.....	فصل دوم : مروری بر مطالعات گذشته.....
۷.....	۱-۲- وسایل و روش‌های تعیین رطوبت خاک.....
۷.....	۱-۱-۲- مقدمه.....
۷.....	۲-۱-۲- روش وزنی.....
۸.....	۳-۱-۲- تانسیومتر.....
۹.....	۴-۱-۲- بلوک گچی.....
۹.....	۵-۱-۲- استفاده از اشعه.....
۹.....	۱-۵-۱-۲- اشعه گاما.....
۱۰.....	۲-۵-۱-۲- نوترون متر.....
۱۱.....	۲-۲- شبکه عصبی مصنوعی (ANN).....
۱۲.....	۱-۲-۲- مدل سازی شبکه مصنوعی در ایران.....
۱۵.....	۲-۲-۲- مدلسازی شبکه عصبی مصنوعی در سایر کشورها.....

۳-۲- تحقیقات انجام شده بر روی TDR در ایران و جهان..... ۱۹

فصل سوم: شبکه‌های عصبی مصنوعی..... ۲۲

۳-۱- آشنایی با شبکه‌های عصبی مصنوعی..... ۲۳

۳-۲- تاریخچه شبکه عصبی مصنوعی..... ۲۴

۳-۳- چرا از شبکه‌های عصبی استفاده می‌کنیم..... ۲۴

۳-۴- ساختار یک سلول شبکه عصبی..... ۲۵

۳-۵- ساختار نرون مصنوعی..... ۲۷

۳-۵-۱- لایه..... ۲۹

۳-۵-۲- وزن..... ۲۹

۳-۵-۳- حافظه..... ۲۹

۳-۶- توابع محرک..... ۳۰

۳-۶-۱- تابع تحریک تانزانانت هیپربولیک..... ۳۰

۳-۷- تناظرین شبکه عصبی زیستی و شبکه عصبی مصنوعی..... ۳۲

۳-۸- نحوه یادگیری در شبکه‌های عصبی مصنوعی..... ۳۲

۳-۹- مراحل یادگیری..... ۳۲

۳-۱۰- انواع یادگیری در شبکه عصبی مصنوعی..... ۳۲

۳-۱۰-۱- یادگیری نظارت نشده یا بدون ناظر..... ۳۲

۳-۱۰-۲- یادگیری نظارت شده یا با ناظر..... ۳۳

۳-۱۱- الگوریتم‌های آموزش..... ۳۳

۳-۱۱-۱- الگوریتم پس انتشار خطا..... ۳۴

۳-۱۲- انواع شبکه‌های عصبی مصنوعی..... ۳۵

۳-۱۲-۱- پرسپترون..... ۳۵

۳-۱۲-۲- الگوریتم فراگیری پرسپترون ساده..... ۳۶

۳-۱۲-۳- شبکه پرسپترون چندلایه..... ۳۷

فصل چهارم: مواد و روش‌ها..... ۴۴

۴-۱- روش انجام کار..... ۴۵

۴-۲- تهیه خاک در سه بافت سبک، متوسط و سنگین..... ۴۵

۴-۳- تهیه ماده آلی..... ۴۶

۴-۴- تهیه خاک با درصدهای مختلف ماده آلی..... ۴۶

۴-۵- تعیین درصد ماده آلی..... ۴۷

۴-۶- مراحل انجام کار..... ۴۷

۴-۶-۱- تهیه مدل شبکه عصبی مصنوعی..... ۴۸

۴-۶-۲- استفاده از ثابت دی‌الکتریک خاک برای تعیین رطوبت خاک..... ۴۸

۴-۶-۲-۱- محاسبه دی‌الکتریک خاک..... ۵۰

۴-۶-۳- تهیه مدل رگرسیون خطی چند متغیره..... ۵۱

فصل پنجم: بحث و نتایج..... ۵۳

۵-۱- مقدمه..... ۵۴

۵۴	۲-۵- پارامترهای ورودی و خروجی.....
۵۴	۳-۵- اجرای شبکه پرسپترون چند لایه (MLP).....
۵۵	۱-۳-۵- بررسی تاثیر توابع انتقال در یادگیری شبکه عصبی مصنوعی.....
۵۵	۲-۳-۵- بررسی تاثیر لایه‌های پنهان در یادگیری شبکه عصبی مصنوعی.....
۵۵	۳-۳-۵- انتخاب بهترین ساختار شبکه عصبی مصنوعی.....
۶۲	۴-۵- تخمین زمانی رطوبت حجمی در سه نوع بافت خاک با شبکه عصبی مصنوعی.....
۶۴	۵-۵- اهمیت پارامترهای ورودی به مدل شبکه عصبی مصنوعی.....
۶۷	۶-۵- برآورد رطوبت حجمی در سه نوع بافت خاک با استفاده از TDR.....
۷۱	۷-۵- اجرای مدل رگرسیون خطی چند متغیره.....
۷۶	فصل ششم: نتیجه‌گیری و پیشنهادها.....
۷۷	۱-۶- نتیجه‌گیری.....
۷۷	۱-۱-۶- شبکه پرسپترون چند لایه (MLP).....
۷۸	۲-۱-۶- مقایسه مدل شبکه عصبی مصنوعی (MLP)، مدل رگرسیون خطی چند متغیره و TDR.....
۸۱	۲-۶- پیشنهادها.....
۸۲	منابع مورد استفاده.....
۹۰	پیوست.....

فهرست شکل‌ها

- شکل ۳-۱- نمایی از آموزش شبکه عصبی مصنوعی با ناظر..... ۲۳
- شکل ۳-۲- نرون طبیعی..... ۲۶
- شکل ۳-۳- نرون تک لایه با یک ورودی..... ۲۷
- شکل ۳-۴- نرون تک لایه با R ورودی..... ۲۸
- شکل ۳-۵- توابع انتقال سیگموئید، گوسین، تانژانت هیپرپولیک و سکانت هیپرپولیک..... ۳۱
- شکل ۳-۶- نمایی از یادگیری نظارت شده..... ۳۳
- شکل ۳-۷- نمایی از پرسپترون چند لایه..... ۳۸
- شکل ۳-۹- نمایش از یک شبکه پرسپترون با سه لایه میانی و محاسبه خروجی نهایی..... ۳۹
- شکل ۵-۱- مقادیر RMSE لایه‌های پنهان متفاوت برای رطوبت حجمی خاک سبک..... ۵۸
- شکل ۵-۲- مقادیر RMSE لایه‌های پنهان متفاوت برای رطوبت حجمی خاک متوسط..... ۵۸
- شکل ۵-۳- مقادیر RMSE لایه‌های پنهان متفاوت برای رطوبت حجمی خاک سنگین..... ۵۹
- شکل ۵-۴- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش در بافت سبک..... ۵۹
- شکل ۵-۵- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی در بافت سبک..... ۶۰
- شکل ۵-۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش در بافت متوسط..... ۶۰
- شکل ۵-۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی در بافت متوسط..... ۶۱
- شکل ۵-۸- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش در بافت سنگین..... ۶۱
- شکل ۵-۹- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی در بافت سنگین..... ۶۲

- شکل ۵- ۱۰- پیش‌بینی منحنی زمانی رطوبت حجمی خاک در بافت سبک (مرحله صحت‌یابی).....۶۳
- شکل ۵- ۱۱- پیش‌بینی منحنی زمانی رطوبت حجمی خاک در بافت متوسط (مرحله صحت‌یابی).....۶۴
- شکل ۵- ۱۲- پیش‌بینی منحنی زمانی رطوبت حجمی خاک در بافت سنگین (مرحله صحت‌یابی).....۶۴
- شکل ۵- ۱۳- سهم پارامترهای ورودی در تخمین رطوبت حجمی خاک در بافت سبک.....۶۵
- شکل ۵- ۱۴- سهم پارامترهای ورودی در تخمین رطوبت حجمی خاک در بافت متوسط.....۶۶
- شکل ۵- ۱۵- سهم پارامترهای ورودی در تخمین رطوبت حجمی خاک در بافت سنگین.....۶۶
- شکل ۵- ۱۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های آموزش به وسیله دستگاه TDR برای بافت سبک.....۶۸
- شکل ۵- ۱۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های صحت‌یابی به وسیله دستگاه TDR برای بافت سبک.....۶۸
- شکل ۵- ۱۸- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های آموزش به وسیله دستگاه TDR برای بافت متوسط.....۶۹
- شکل ۵- ۱۹- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های صحت‌یابی به وسیله دستگاه TDR برای بافت متوسط.....۶۹
- شکل ۵- ۲۰- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های آموزش به وسیله دستگاه TDR برای بافت سنگین.....۷۰
- شکل ۵- ۲۱- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های صحت‌یابی به وسیله دستگاه TDR برای بافت سنگین.....۷۰
- شکل ۵- ۲۲- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون در بافت سبک.....۷۳
- شکل ۵- ۲۳- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی مدل رگرسیون در بافت سبک.....۷۳
- شکل ۵- ۲۴- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون در بافت متوسط.....۷۴
- شکل ۵- ۲۵- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی مدل رگرسیون در بافت متوسط.....۷۴

شکل ۵-۲۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیون در بافت سنگین.....۷۵

شکل ۵-۲۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی مدل رگرسیون در بافت سنگین.....۷۵

فهرست جدول‌ها

جدول ۱-۳- تناظر بین شبکه عصبی زیستی و شبکه عصبی مصنوعی.....۳۱

جدول ۴-۱- درصد ماده آلی بافت‌های مورد مطالعه.....۴۷

جدول ۴-۲- پارامترهای آماری داده‌های مورد استفاده شده در سه بافت سبک، متوسط و سنگین.....۵۲

جدول ۵-۱- نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین.....۵۷

جدول ۵-۲- نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین زمانی رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین.....۶۳

جدول ۵-۳- نتایج حاصل از اجرای روش TDR برای تخمین رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین.....۶۷

جدول ۵-۴- نتایج حاصل از اجرای روش مدل رگرسیون خطی چند متغیره برای تخمین رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین.....۷۲

جدول ۶-۱- نتایج حاصل از اجرای روش مدل شبکه عصبی مصنوعی، رگرسیون خطی چند متغیره و TDR برای تخمین رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین.....۸۰

فصل اول

کلیات

۱-۱- مقدمه

با شناخت توانایی سلول‌های عصبی در مغز انسان و مشابه‌سازی این روند در سیستم‌های کامپیوتری، شبکه‌های عصبی هوشمند مصنوعی برای نخستین بار در سال ۱۹۴۳ توسط مک کالوخ (عصب‌شناس) و پیت (ریاضیدان) به وجود آمد و از آنجایی که مفاهیم پایه‌ای مطرح شده در مباحث مربوط به آن از اساس ریاضی مستحکم و قابل اعتمادی برخوردار بود، بعدها به طور گسترده‌ای مورد اقبال عمومی پژوهش‌گران در مدل‌سازی تجربی فرآیندهای شدیداً غیرخطی قرار گرفت (Haykin., ۱۹۹۹). شبکه عصبی، شبیه‌سازی از دستگاه عصبی انسان است و در واقع تقلیدی از مغز و شبکه اعصاب انسان می‌باشد. در این شبکه سعی بر این است که ساختاری تهیه شود که همانند مغز انسان، قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (منهاج، ۱۳۷۷). در این گونه ساختارها هدف این است که با معرفی عملکرد یک سیستم دینامیکی، مدل را آموزش داده، چگونگی عملکرد در حافظه مدل ذخیره و از آن برای مواردی که قبلاً با آن مواجه نشده است، استفاده شود. به دلیل توانایی این شبکه‌ها در مدل‌سازی، فرایندهای بسیار پیچیده، که تعداد عوامل تاثیرگذار در آنها زیاد است، استفاده از آنها در علوم کشاورزی فراهم می‌باشد.

مهم‌ترین بخش یک شبکه عصبی نرون (Neuron) است. نرون‌ها سلول‌های تشکیل‌دهنده دستگاه عصبی انسان هستند. به طور کلی، نرون کوچک‌ترین واحد پردازشگر اطلاعات است که اساس عملکرد شبکه را تشکیل می‌دهد. هر شبکه عصبی مصنوعی از لایه‌های ورودی، پنهان و خروجی تشکیل شده است. در هر لایه، یک یا چند عنصر پردازشگر (نرون) وجود دارد که عملکرد آنها شبیه به عملکرد نرون‌های مغز انسان است علاوه بر این هر لایه دارای وزنی است که بیانگر میزان تاثیر دو نرون بر یکدیگر است. یک شبکه عصبی مصنوعی مجموعه‌ای از نرون‌هایی است که در آن هر نرون با همه نرون‌های لایه بعدی مرتبط است. شبکه‌های عصبی با توانایی قابل توجه خود در استنتاج نتایج از داده‌های پیچیده می‌توانند در استخراج الگوها و شناسایی گرایش‌های مختلفی که برای انسان‌ها و

کامپیوتر شناسایی آنها بسیار دشوار است استفاده شوند. شبکه‌های عصبی در مسیری گام بر می‌دارند که ابزارها توانایی فراگیری و برنامه‌ریزی خود را داشته باشند. ساختار شبکه عصبی به گونه‌ای است که قابلیت حل مسئله را بدون فرد متخصص و برنامه‌ریزی خارجی دارد. شبکه‌های عصبی قادر به یافتن الگوهای در اطلاعات هستند که هیچ‌کس، هیچ‌گاه از وجود آنها اطلاع نداشته است. امروزه شبکه‌های عصبی مصنوعی به عنوان یک روش درون‌باب و شبیه‌ساز پیشرفته که به خوبی توانایی شبیه‌سازی فرآیندهای پیچیده را دارد، به کار می‌رود. در واقع به کارگیری این روش افق جدیدی را در خانواده مهندسی و پس از آن در شاخه‌های دیگر علوم گشود. (منهاج، ۱۳۸۱)

۲-۱- ضرورت تحقیق

گیاه آب مورد نیاز خود را از طریق ریشه‌ها از خاک جذب می‌نماید. بنابراین موجودیت و قابل استفاده بودن آب در خاک از عوامل اصلی رشد گیاه است. علاوه بر این بسیاری از خصوصیات خاک‌ها مانند پایداری، خاصیت خمیرایی، مقاومت، قابلیت فشرده شدن و نفوذپذیری به مقدار آب بستگی دارد. رطوبت خاک بر مقدار هوای موجود در خاک و تبادل گازها در آن موثر است. فعالیت موجودات ریز خاک و کنش‌های شیمیایی خاک نیز تابعی از میزان رطوبت آن است.

تعیین رطوبت حجمی خاک و آب قابل دسترس برای گیاهان در زمینه‌های متعدد مانند حفاظت آب و خاک، هیدرولوژی مهندسی آب بسیار مهم است. بنابراین بررسی رطوبت خاک و میزان قابل استفاده آن برای گیاه از مهم‌ترین موضوعات در علم رابطه آب، خاک و گیاه است. در راستای ارزیابی روش‌ها و تکنیک‌های جدیدی که محدودیت‌های روش متداول را نداشته باشد و به منظور صرفه جویی در زمان، هزینه و بالا بردن دقت بررسی‌ها، تحقیق حاضر صورت گرفته است. همچنین در این بررسی به اندازه‌گیری زمانی رطوبت حجمی در بافت‌های مختلف خاک که در بسیاری از مطالعات خاکشناسی و هیدرولوژی مورد نیاز است، پرداخته شده است.

۱-۳- اهداف

اهداف کلی این تحقیق را که در آن به تخمین رطوبت حجمی خاک توسط شبکه عصبی مصنوعی پرداخته شده است را می‌توان به شرح زیر خلاصه کرد:

۱. تخمین رطوبت خاک با استفاده از شبکه عصبی مصنوعی

۲. بررسی توانایی‌های مدل رگرسیون خطی چند متغیره در تخمین رطوبت حجمی خاک

۳. مقایسه نتایج حاصل از مدل شبکه عصبی با رگرسیون خطی در تخمین رطوبت حجمی خاک

۴. بررسی تفاوت موجود بین مدل شبکه عصبی با روش انعکاس سنجی حوزه زمانی (Reflectometry Time Domaine) که اصطلاحاً TDR نام گرفته است.

۵. تاثیر اثرگذارترین پارامترها بر رطوبت حجمی خاک با انجام آنالیز حساسیت.

۴-۱- روش تحقیق

روش انجام این پروژه مبتنی بر تعیین قابلیت مدل شبکه عصبی (MLP) در تخمین رطوبت حجمی خاک می‌باشد.

به منظور انجام تحقیق از پارامترهای اندازه‌گیری شده در شرایط آزمایشگاهی بر روی سه بافت سبک، متوسط، و سنگین با درصدهای مختلف ماده آلی به صورت دست خورده درون گلدان‌هایی به ارتفاع ۲۵/۵ سانتی‌متر و قطر ۲۵ سانتی‌متر که توسط مزیدی و معروف پور (۱۳۸۹) اندازه‌گیری شد مورد استفاده قرار گرفت. این پارامترها که عبارتند از: ۱- بافت خاک ۲- درصد ماده آلی ۳- وزن مخصوص حقیقی ۴- وزن مخصوص ظاهری ۵- تخلخل .

سپس داده‌ها پس از تقسیم شدن به دو بخش آموزش و صحت‌سنجی، با مدل MLP شبکه عصبی که از روش پس انتشار خطا برای آموزش کمک می‌گیرد بررسی شدند. نتایج حاصل از کار با شبکه عصبی MLP با نتایج مدل رگرسیون خطی چند متغیره که بر خلاف مدل شبکه عصبی تنها قادر به تعیین روابط خطی میان پارامترهای مستقل با پارامترهای وابسته می‌باشد، مقایسه گردید.

فصل دوم

مروری بر

مطالعات گذشته

۲-۱- وسایل و روش‌های تعیین رطوبت خاک

۲-۱-۱- مقدمه

به مقدار آب موجود در واحد جرم یا حجم خاک رطوبت خاک گفته می‌شود که به دو صورت مستقیم و غیر مستقیم اندازه‌گیری می‌شود. برخی از روش‌های اندازه‌گیری رطوبت، مستقیماً در مزرعه کاربرد دارند و یا باید از خاک نمونه‌برداری کرد و مقدار رطوبت را در آزمایشگاه تعیین نمود که همان روش تعیین درصد رطوبت وزنی از طریق خشک کردن نمونه خاک در آون در دمای ۱۰۵ درجه سانتیگراد و به مدت ۲۴ ساعت، و تبدیل آن به رطوبت حجمی با اعمال وزن مخصوص ظاهری می‌باشد. در روش غیر مستقیم باید از اندازه‌گیری یک عامل که بر درصد رطوبت موثر است، استفاده کرد. روش‌ها و ابزار مختلفی برای نمایش یا تعیین مستقیم رطوبت خاک استفاده می‌شوند که می‌توانند رطوبت را به صورت وزنی، حجمی و پتانسیل مشخص نمایند. متداول‌ترین آنها عبارتند از:

۱- نمونه‌گیری وزنی

۲- تانسیومتر

۳- بلوک گچی

۴- استفاده از اشعه (اشعه گاما و نوترون متر)

۵- استفاده از ثابت دی‌الکتریک خاک

۲-۱-۲- روش وزنی

روش وزنی عبارت است از خشک کردن نمونه مرطوب در آون در دمای ۱۰۵ درجه سانتی‌گراد، تا زمانی که در اثر خشک شدن تغییری در وزن مشاهده نشود. تفاوت بین جرم اولیه (m_i) و جرم پایانی

(m_f) مقدار رطوبت خاک را به دست می‌دهد.

$$\theta_m = \frac{m_i - m_f}{m_f} \times 100 \quad (1-2)$$

در بسیاری از آزمایشگاه‌ها، مدت زمان ۲۴ ساعت را برای خشک کردن بکار می‌برند که تقریباً برای اکثر خاک‌ها مناسب است.

با داشتن وزن مخصوص ظاهری (ρ_b) و رطوبت وزنی (θ_m) می‌توان رطوبت حجمی (θ_v) را محاسبه نمود.

$$\theta_v = (\rho_b) \times \theta_m \quad (2-2)$$

۲-۱-۳- تانسیومتر

مکش آب خاک یا پتانسیل رطوبتی خاک، میزان انرژی موجود در خاک را برای نگهداری آب نشان می‌دهد. پتانسیل آب خاک، میزان انرژی است که آب خاک در مقایسه با سطح انرژی آزاد دارا می‌باشد. از منحنی رطوبتی خاک برای نمایش رابطه بین رطوبت و مکش خاک استفاده می‌شود (جعفری حقیقی، ۱۳۸۲).

کارایی تانسیومترها فقط در پتانسیل ۰/۸۵ اتمسفر (۸۵۰ سانتی‌متر آب) است. چون خلأسنج یا فشار سنج جیوه‌ای، اندازه نسبی خلأ را در مقابل فشار اتمسفر اندازه‌گیری می‌کند، اگر خاک اشباع یا تحت فشار مثبت باشد آب وارد تانسیومتر شده و عقربه شروع به بالا رفتن می‌کند و در این حالت فشار اضافی با فشارسنج اندازه‌گیری می‌شود. بر خلاف اسم آن، هم فشار مثبت و هم فشار منفی را تعیین می‌کند اما چون خاک غیر اشباع بوده اندازه‌گیری فشار منفی با آن معمول است. برای استفاده از تانسیومتر یک منحنی کالیبراسیونی نیاز است که ارتباط آب موجود را با فشار کاپیلاری اندازه‌گیری شده نشان دهد (علیزاده، ۱۳۸۰).

۲-۱-۴ بلوک گچی

هدایت الکتریکی تابعی از املاح محلول در غلظت‌های مختلف است که خود تحت تاثیر رطوبت قرار دارد. اگر هدایت الکتریکی خاک تعیین شده باشد می‌توان رطوبت خاک را تعیین کرد. بلوک گچی علاوه بر دو الکتروود برای اندازه‌گیری مقاومت، یک سنسور هم برای اندازه‌گیری درجه حرارت دارد. دامنه کاری بلوک‌های گچی در مکش‌های ۵ تا ۵۰ بار است و در خاک‌های رسی کارایی بهتری دارد. برای استفاده از این بلوک‌ها یک منحنی کالیبراسیونی نیاز است که ارتباط آب موجود را با مقاومت الکتریکی اندازه‌گیری شده نشان دهد (علیزاده، ۱۳۸۰).

۲-۱-۵- استفاده از اشعه

دو روش استفاده از اشعه در اندازه‌گیری رطوبت وجود دارد که عبارتند از: روش‌های اشعه گاما و نوترون متر (جعفری حقیقی، ۱۳۸۲).

۲-۱-۵-۱ اشعه گاما

ذرات خاک و ملکول‌های آب توانایی جذب اشعه گاما را دارند. مقدار نسبی جذب به انرژی اشعه گاما بستگی دارد. با این روش می‌توان رطوبت خاک را در آزمایشگاه و صحرا تعیین کرد. روابط مورد استفاده به شرح زیر می‌باشند:

$$\frac{N_m}{N_0} = \exp(-X(\mu_s \rho_b + \mu_w \theta_m)) \quad (2-5)$$

N : شمارش اشعه انتقال یافته از طریق هوا از منبع تولید کننده اشعه،

N_m : اشعه انتقال یافته از خاک مرطوب،

X : طول مسیر،

ρ_b : وزن مخصوص ظاهری،

Θ_m : رطوبت وزنی

μ_s و μ_w : ضرایب جذب اشعه برای خاک و آب می‌باشند.

در خاک خشک $\Theta = 0$ است و معادله (۲-۵) به صورت زیر در می‌آید:

$$\frac{N_m}{N_o} = \exp(-X\mu_s\rho_b) \quad (۲-۶)$$

با استفاده از معادله‌های (۲-۵) و (۲-۶) می‌توان رطوبت را محاسبه کرد:

$$\theta_m = \frac{\ln(N_o/N_m)}{X\mu_w} \quad (۲-۷)$$

روش استفاده از اشعه گاما برای اندازه‌گیری وزن مخصوص ظاهری و رطوبت خاک‌های منبسط شونده مثل ورتی‌سویل‌ها مناسب نمی‌باشد. این روش بیشتر در آزمایشگاه‌ها و برای اندازه‌گیری نفوذ آب در خاک و به دست آوردن موقعیت دقیق جبهه رطوبتی مناسب است (جعفری حقیقی، ۱۳۸۲).

۲-۱-۵-۲- نوترون متر

در این روش، نوترون‌های دارای سرعت زیاد و انرژی زیاد بوده و با هسته‌های اتم هیدروژن برخورد خواهند کرد. اگر هسته دارای جرم بیشتری از جرم نوترون باشد نوترون‌ها دارای سرعتی معادل سرعت قبل از برخورد با هسته می‌باشند اما اگر جرم نوترون و هسته باهم برابر باشند مقداری از انرژی نوترون توسط هسته گرفته شده و باعث پخش نوترون‌ها می‌شود. پس از برخورد متمادی نوترون‌ها به هسته، سرعت آنها کاهش می‌یابد تا جایی که انرژی جنبشی آن ($1/2 \text{ mV}$) برابر با انرژی هسته شود. به این پدیده حرارتی شدن گویند. هسته‌های هیدروژن جرمی معادل یک هزارم جرم نوترون دارند. آب خاک نوترون‌ها، نوترون متر برای اندازه‌گیری رطوبت ساخته شده‌است و فقط یک بار نیاز به واسنجی دارد.

$$\theta_v = \frac{R_s}{R_{std}} b + j \quad (8-2)$$

در این رابطه b و j : ثابت‌های معادله، R_s : سرعت شمارش دستگاه در خاک و R_{std} : سرعت شمارش استاندارد است. با نمونه برداری و اندازه‌گیری رطوبت می‌توان θ_v را به دست آورد.

گریسین (۱۹۸۱) رابطه زیر را برای محاسبه رطوبت با این دستگاه ارائه داد:

$$\theta_v = a + bC_f \quad (9-2)$$

در این رابطه C_f : مقدار شمارش نوترون متر و a و b ضرایب معادله هستند. البته نباید از واسنجی ساده بین θ_v و C_f استفاده کرد و بهترین روش تخمین θ_v به صورت زیر است:

$$\theta_v = \frac{a}{b'} + \frac{1}{b'} cf \quad (10-2)$$

که a و b به ترتیب عرض نقطه تقاطع منحنی با محور Y ها و شیب منحنی واسنجی بین θ_v و C_f می‌باشند. این روش رطوبت حجمی را اندازه‌گیری می‌کند و دقت آن ± 2 میلی‌متر در 450 میلی‌متر آب خاک تا عمق $1/5$ متری است (بای‌پوردی، ۱۳۷۲).

۲-۲- شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی، ساختاری (شبکه ای) است متشکل از تعدادی واحد (نرون های مصنوعی) که در داخل شبکه به هم وصل شده اند. هر واحد دارای یک مشخصه ورودی/خروجی (I/O) می باشد و محاسبه یا عملی جزئی را اجرا می‌کند. خروجی هر واحد، با توجه به مشخصه (I/O) آن، اتصالات درونیش به سایر واحدها و (احتمالاً) ورودی‌های خارجی تعیین می‌گردد. از آنجا که آموزش دستی شبکه امکان پذیر است، از این رو شبکه معمولاً کارکردی کلی از یک حالت یا حالت‌های بیشتری از آموزش را به دست می آورد. ANN متشکل از یک شبکه نیست، بلکه خانواده‌ای متشکل از

شبکه‌های گوناگون می‌باشد. عمل یا عملکرد کلی شبکه‌های عصبی مصنوعی، توسط توپولوژی شبکه، خصوصیات نرون منفرد و تاکتیک یادگیری و داده‌های آموزش معین می‌شود.

۲-۲-۱- مدل سازی شبکه مصنوعی در ایران

بررسی منابع نشان می‌دهد تا به حال از مدل شبکه عصبی مصنوعی در کارهای مختلفی مانند خاک، محیط زیست، منابع آب و هیدرولیک رسوب مورد استفاده قرار گرفته است. برای مثال 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 معنی‌دار در سطح احتمال ۱ 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. امامی و همکاران، (۱۳۸۶) در بررسی خود با عنوان ارزیابی کارایی شبکه‌های عصبی مصنوعی در برآورد منحنی رطوبتی خاک در بعضی خاک‌های شور و آهکی ایران با بررسی مقادیر ضریب همبستگی، ضریب تبیین، ضریب تبیین اصلاح شده و مقادیر خطا، به کارایی شبکه عصبی مصنوعی پرداختند و به همبستگی مثبت و معنی‌دار بین رطوبت‌های تخمینی و اندازه‌گیری شده در سطح آماری ۱ درصد دست پیدا کردند. در بررسی دیگری از شبکه عصبی مصنوعی و رگرسیون چند متغیره تطبیقی برای پیش‌بینی آب قابل جذب گیاه استفاده گردید. داده‌های ورودی شامل درصد شن، سیلت و رس، درصد اشباع خاک از آب، متوسط وزنی قطر خاکدانه‌ها، وزن مخصوص حقیقی، ظرفیت تبادل کاتیونی، درصد ماده آلی، اسیدیته و درصد کربنات کلسیم معادل بودند. نتایج حاکی از کارکرد مناسب هر دو مدل بود (گیوی و پراشر، ۱۳۸۴).

سرمدیان و همکاران (۱۳۸۸) از روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی ویژگی‌های رطوبت در نقطه ظرفیت زراعی (FC) و نقطه پژمردگی (PWP)، وزن مخصوص ظاهری (BD) و ظرفیت تبادل کاتیونی (CEC) استفاده کردند. آنها با اندازه‌گیری فراوانی نسبی ذرات،

کربن آلی، درصد رطوبت اشباع و آهک به عنوان ویژگی‌های زود یافت به تخمین پارامترهای ذکر شده پرداختند. نتایج آنها نشان دهنده کارایی بالاتر مدل نروفازی و شبکه عصبی نسبت به روش رگرسیونی بود. گروهی از محققین امکان برآورد سریع هدایت آبی اشباع خاک توسط شبکه عصبی مصنوعی را بررسی و نتیجه گرفتند که در این مورد شبکه‌های عصبی مصنوعی در مقایسه با روابط رگرسیونی عملکرد نسبتاً بهتری دارند (نوابیان و همکاران، ۱۳۸۳). نجفی نیسانی (۱۳۸۵) در تحقیقی با عنوان برآورد بار رسوب رودخانه زاینده رود با استفاده از شبکه عصبی مصنوعی به مقایسه مدل‌های پرسپترون چند لایه (MLP) و توابع شعاعی (GRNN) و رگرسیون خطی پرداختند که در آن به کارایی بالای مدل پرسپترون چند لایه نسبت به سایر مدل‌ها دست پیدا کردند. 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. نامدار خجسته و همکاران (۱۳۸۸) برای اندازه‌گیری EC محلول خاک به وسیله TDR از شبکه عصبی مصنوعی استفاده کردند و با مقایسه میزان RMSE دو رابطه تجربی و مدل شبکه عصبی مصنوعی به کارایی بالای مدل شبکه عصبی مصنوعی دست پیدا کردند. حسین شیرانی و همکاران (۱۳۸۹) توابع انتقالی برای FC و PWP برخی از خاک‌های استان کرمان با استفاده از رگرسیون آماری و مدل شبکه عصبی تعیین کردند بدین منظور ۱۰۰ نمونه خاک از مناطق مختلف کرمان از عمق صفر تا ۳۰ سانتی متری گرفته شد. سپس ویژگی‌هایی از قبیل FC و PWP (ویژگی‌های دیریافت خاک) و درصد رس، سیلت، شن، آهک، ماده آلی و گچ (خواص زود یافت خاک) برای تمامی نمونه‌ها اندازه‌گیری شد. توابع انتقالی از دو روش رگرسیون و شبکه عصبی تعیین گردید. نتایج نشان داد که شبکه عصبی عملکرد بهتری نسبت به مدل‌های رگرسیونی دارد. دعایی و همکاران (۲۰۰۵) از ۲۲ نمونه خاک رسی استان گیلان با استفاده از پارامترهای فیزیکی درصد رس، 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 دقیق‌ترین تخمین را در

مدل سازی ضریب آبگذری اشباع نشان می‌دهد. نوایان و همکاران (۲۰۰۴) از ۴۵ نمونه خاک برای برآورد هدایت آبی اشباع با استفاده از شش پارامتر فیزیکی و شیمیایی ورودی توسط شبکه عصبی مصنوعی استفاده کردند. و مدل آنها دارای عملکرد مناسب تری نسبت به مدل آماری بود که علت عملکرد مناسب تر شبکه عصبی را به هوشمند بودن نحوه تجزیه و تحلیل داده‌ها نسبت داده‌اند. نامدار خجسته و همکاران (۱۳۹۰) برای برآورد رطوبت حجمی خاک به وسیله TDR از شبکه عصبی مصنوعی استفاده کردند. نتایج نشان داد عامل‌های وزن مخصوص ظاهری و مقدار رس بیشترین تاثیر را در شبکه داشتند و شبکه با این دو عامل ورودی، کمترین مقدار RMSE را در بین توپولوژی‌های بررسی شده نشان داد. و مدل شبکه عصبی بهتر از مدل‌های بیرچاک و همکاران، والی، تاپ و همکاران با مقدار RMSE کمتر، مقدار رطوبت را پیش‌بینی می‌کند. در میان مدل‌های بررسی شده معادله تاپ، نتایج ضعیف‌تری نسبت به دیگر مدل‌ها نشان داد. خلیلی مقدم و افیونی، (۱۳۸۹) با کاربرد روش‌های رگرسیونی و شبکه عصبی در تشکیل توابع انتقالی خاک به منظور تخمین هدایت هیدرولیکی اشباع خاک منطقه زاگرس مرکزی، کارایی بالای مدل شبکه عصبی مصنوعی را در مقایسه با رگرسیون چند متغیره خطی توسط بررسی ضریب همبستگی و چندین فاکتور اندازه‌گیری خطا، به دست آوردند. مهربانیان و همکاران، (۱۳۸۹) از مدل شبکه عصبی برای تخمین ظرفیت تبادل کاتیونی خاک‌های آهکی و گچی استان یزد استفاده کردند و با اندازه‌گیری پارامترهای اجزا بافت خاک و درصد کربن آلی خاک به پیش بینی ظرفیت تبادل کاتیونی با مدل‌های شبکه عصبی و رگرسیون خطی پرداختند. نتایج آنها کارایی بالای شبکه عصبی را که دارای روابط غیرخطی میان متغیرهای وابسته و پیش بینی شونده می‌باشد را در مقایسه با روابط رگرسیونی به خوبی نشان داد. صفاری و همکاران (۱۳۸۸) به مقایسه روش‌های میان‌یابی کریجینگ و شبکه عصبی مصنوعی برای پیش بینی تغییرات مکانی بعضی از خصوصیات شیمیایی خاک استفاده کردند. خصوصیات شیمیایی خاک شامل هدایت الکتریکی، کلسیم، منیزیم و پتاسیم بودند. برای مقایسه و بررسی دقت مدلها از پارامترهای میانگین خطای مطلق (MAE)، مجذور میانگین مربعات خطا (RMSE) و ضریب همبستگی (r) استفاده شد. نتایج

حاکمی از برتری مدل شبکه عصبی مصنوعی که از روش پس انتشار خطا برای آموزش کمک می گیرد، بوده است. نژادکابی و همکاران (۱۳۸۸) برای برآورد میزان TDS آب از مدل‌های MLP و RBF شبکه عصبی مصنوعی، نروفازی، روابط تجربی و روش رگرسیونی استفاده کردند. نتایج آنها نشان دهنده کارایی بالای مدل نروفازی در مرحله آموزش و مدل‌های MLP و RBF شبکه عصبی مصنوعی و مدل نروفازی در مرحله ارزیابی بوده است. همچنین تمامی مدل‌های به کار برده شده نسبت به روابط تجربی دقت بالاتری را نشان دادند.

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

مارسل و همکاران (۱۹۹۸) مدل شبکه عصبی را برای پیش‌بینی ظرفیت نگهداری رطوبت و هدایت الکتریکی در حالت اشباع با استفاده از خصوصیات پایه خاک شامل مقادیرشن، سیلت، وزن مخصوص ظاهری، تخلخل و مقدار گراول بکار بردند و نتیجه گرفتند که به طور کلی با افزایش تعداد داده‌ها پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی در حالت اشباع بهبود می‌یابد و استفاده از این روش به دلیل دقت و میزان انعطاف پذیری زیاد در مقابل داده‌های در دسترس مورد توجه قرار گرفت. پاچپسکی و همکاران (۱۹۹۶) برای سنجش مقدار رطوبت خاک در پتانسیل‌های مختلف ماتریک، با استفاده از داده‌های سهل الوصول از روش شبکه‌های عصبی مصنوعی (ANN) استفاده کردند. آنها اظهار داشتند این روش یکی از ابزارهای عمومی برای مدل‌سازی است و در شرایطی که وابستگی‌های پیچیده بین داده‌های ورودی- خروجی سیستم موجود باشد، کاربرد دارد. آنها در تحقیق خود دقت روش ANN و مدل‌های رگرسیونی را برای تخمین آب نگهداری شده خاک، با استفاده از بافت و وزن مخصوص ظاهری مقایسه کردند. نتایج آنها نشان داد، تفاوت معنی‌داری در دقت پیش‌بینی‌های با روش‌های ذکر شده بالا وجود ندارد. گرچه ANN همواره مقدار آب را در هر پتانسیل بهتر از مدل‌های رگرسیونی تخمین زده است. ضمناً از روش ANN و مدل‌های رگرسیونی با استفاده از داده‌های موجود (بافت و وزن مخصوص ظاهری) مقادیر ضرایب معادله وانگنختن تخمین زده شد. نتایج نشان داد

تخمین ضرایب معادله وانگنختن توسط همه مدل‌ها (ANN و رگرسیونی) موجب برآورد کمتر مقدار رطوبت خاک نسبت به مقادیر آزمایشگاهی شده است. پینگ زو (۲۰۱۰) از شبکه عصبی مصنوعی به منظور پیش‌بینی شوری و میزان آب خاک مورد استفاده قرار داد. در مطالعه‌ای که توسط مردون و همکاران (۲۰۰۶) انجام شد، توابع انتقالی برای نقاط (FC و PWP) با استفاده از توزیع اندازه ذرات و جرم مخصوص ظاهری توسط شبکه عصبی و رگرسیون چند متغیره‌ی خطی به دست آمد و کارایی این روش‌ها با نتایج اندازه‌گیری‌های مستقیم مقایسه گردید. برای دانستن میزان اعتبار توابع انتقالی خاک، ۱۹۵ نمونه خاک به دو گروه تقسیم شد، یک گروه شامل ۱۳۰ نمونه و گروه دیگر شامل ۶۵ نمونه خاک بود. اگر چه تفاوت نتایج بین دو روش در سطح ۵٪ معنی‌دار نبود، ولی رگرسیون چند متغیره خطی تخمین بهتری ارائه داد و هر دو روش در تعداد نمونه بیشتر، دقت بالاتری را نشان دادند (مردون و همکاران، ۲۰۰۶). طارقیان و کاشفی پور (۲۰۰۷) دبی ورودی به سد دز را با استفاده از سیستم فازی و عصبی مورد بررسی قرار دادند. سارانگی و بیهاتا چاریا (۲۰۰۵) در حوزه (Banha) هندوستان با استفاده از مدل‌های شبکه عصبی مصنوعی و مدل‌های رگرسیونی دبی رسوب را برای هر دو مدل برآورد کرده و نتیجه گرفتند مدل شبکه عصبی مصنوعی از دقت بالایی برخوردار است. کاشفی پور و همکاران (۲۰۰۵) غلظت کالیفرم را در آبهای ساحلی دریایی واقع در غرب اسکاتلند به کمک ANN مدل نمودند. شاهین و همکاران (۲۰۰۱) در خصوص تعیین خصوصیات ژئوتکنیکی خاک‌ها و برآورد میزان دقت ANN تحقیقاتی انجام دادند. پاراسورامن و همکاران (۲۰۰۶) برای برآورد هدایت آبی اشباع در مقیاس مزرعه‌ای، دو گروه شبکه عصبی طراحی نمودند. در گروه اول از ویژگی‌های مقدار رس، سیلت و شن به عنوان ورودی‌های شبکه استفاده گردید و در گروه دوم علاوه بر سه ویژگی یاد شده، جرم مخصوص ظاهری نیز به عنوان ورودی مدل مورد استفاده قرار گرفت. نتایج این پژوهش نشان داد که شبکه‌های عصبی طراحی شده عملکردی بهتر در برآورد هدایت آبی اشباع در مقایسه با شبکه عصبی Rosetta داشته‌اند. مینسنی و مک برتنی (۲۰۰۲) برای برآورد پارامترهای مدل ون‌گنختن در خاک‌های استرالیا از شبکه‌های عصبی مصنوعی استفاده نمودند. این

پژوهشگران در طراحی شبکه عصبی مصنوعی تابع هدف جدیدی ارائه نمودند. در این پژوهش به جای اینکه تابع هدف مورد نظر را با استفاده از پارامترهای ون گنختن تعیین کنند، از مقدار رطوبت برآورد شده از مدل ون گنختن استفاده نمودند. نتایج این پژوهش نشان داد که تابع هدف ارائه شده اثری قابل قبول در بهبود عملکرد شبکه داشته است. اسخاپ و لای (۱۹۹۸) با استفاده از شبکه‌های عصبی مصنوعی موفق به برآورد پارامترهای مدل‌های ون گنختن (۱۹۸۰) و گاردنر (۱۹۵۸) گردیدند این پژوهشگران در ابتدا با استفاده از ورودی‌های فراوانی نسبی ذرات، شبکه‌های مورد نظر را طراحی نمودند. سپس به صورت سلسله‌وار ورودی‌های جدیدی به شبکه‌ها اضافه نمودند و در هر مرحله عملکرد شبکه‌های طراحی شده را مورد ارزیابی قرار دادند. نتایج این پژوهش نشان داد با ورود متغیرهای جدید به شبکه به عنوان برآورد کننده، عملکرد شبکه در برآورد پارامترهای یاد شده بهبود یافت. با این وجود، این پژوهشگران تفاوتی قابل ملاحظه بین مقادیر اندازه‌گیری شده و برآورد شده مشاهده نمودند. (Bell and Vankelon, ۱۹۹۵) با استفاده از متغیرهای مقدار رس، ماده آلی و اسیدیته خاک تابعی برای برآورد ظرفیت تبادل کاتیونی ارائه نمودند. (Krogh et al., ۲۰۰۰) با استفاده از متغیرهای مقدار ماده آلی، رس، سیلت ریز و اسیدیته خاک در عصاره کلرور کلسیم توابعی برای ظرفیت تبادل کاتیونی ارائه دادند. (Vos et al., ۲۰۰۵) برای تخمین وزن مخصوص ظاهری از ۱۲ تابع انتقالی استفاده کردند و نتایج ایشان نشان داد که جدا کردن داده‌های خاک سطحی و زیرین دقت پیش‌بینی را بالا نبرده است. (Kaur et al., ۲۰۰۲) و (Heuser et al., ۲۰۰۵) در مطالعات خود به این نتیجه رسیدند که بافت و مواد آلی مولفه‌های اصلی در تعیین وزن مخصوص ظاهری می‌باشد. (Givi et al., ۲۰۰۴) ۱۳ تابع انتقالی نقطه‌ای و پارامتری را برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی دائم استفاده کردند. نتایج این پژوهشگران نشان داد که توابع انتقالی که در خاک‌های مشابه اشتقاق پیدا کرده‌اند، دارای کمترین خطا می‌باشند. (Schap et al., ۱۹۹۸) نشان دادند که شبکه‌های عصبی می‌تواند پیش‌بینی‌هایی با خطاهای کمتر نسبت به روش‌های متداول رگرسیونی ارائه دهد. (Parasuraman et al., ۲۰۰۶) بیان داشتند که شبکه عصبی مصنوعی کارایی بهتری نسبت به شبکه

عصبی رزتا در تخمین ویژگی‌های هیدرولیکی خاک داشته است که این نشان‌دهنده اهمیت فرایند آموزش در شبکه عصبی می‌باشد. (Amini et al., ۲۰۰۵) با استفاده از میزان ماده آلی و رس اقدام به برآورد میزان ظرفیت تبادل کاتیونی خاک به وسیله شبکه عصبی و پنج مدل تجربی که بر پایه روش‌های رگرسیونی می‌باشند نمودند و نتایج این محققین نشان داد که روش شبکه عصبی از برتری قابل قبولی نسبت به سایر روش‌ها برخوردار می‌باشد. با این وجود (Tamari et al., ۱۹۹۶) نشان داد که اگر ناپایداری داده‌ها بالا باشد، شبکه عصبی از مدل‌های رگرسیون خطی بهتر نخواهد بود، اما زمانی که داده‌هایی با دقت بالا به کار برده شود شبکه عصبی کارایی بالاتری را نشان می‌دهد. (Kalkan et al., ۲۰۰۸) برای پیش‌بینی مقاومت در برابر فشار از توزیع اندازه ذرات خاک استفاده کرده و برای مدل کردن از دو روش نروفازی و شبکه عصبی استفاده کردند. نتایج نشان از کارایی بالاتر نروفازی در این تحقیق داشت. صفاری و همکاران (۲۰۰۹) برای ارزیابی تغییرپذیری خصوصیات شیمیایی تعدادی از خاک‌ها، از مدل شبکه عصبی مصنوعی استفاده کردند و به کارایی بالای آن با وجود یک لایه پنهان دست یافتند. برخی محققین به تخمین میزان فرسایش و رواناب پرداختند و به دقت بالای شبکه عصبی مصنوعی دست پیدا کردند (Licznar and Nearing, ۲۰۰۳).

(Ibrahim Ekhmaj ۲۰۱۰) با استفاده از پارامترهایی شامل رس، شن، سیلت، وزن مخصوص ظاهری، هدایت هیدرولیکی اشباع و حجم آب در خاک به پیش‌بینی میزان نفوذپذیری خاک توسط مدل شبکه عصبی مصنوعی و مدل رگرسیون خطی پرداخت. نتایج او نشان دهنده کارایی بالاتر مدل شبکه عصبی نسبت به رگرسیون خطی می‌باشد. راب و همکاران (۲۰۰۹) از شبکه‌های MLP و RBF برای برآورد شاخص‌های ناهمگنی خاک استفاده کردند که طبق بررسی‌های آنها، شبکه MLP از کارایی بالاتری برخوردار بود. در تحقیق دیگری توسط امینی و همکاران (۲۰۰۵) به تخمین ظرفیت تبادل کاتیونی در مناطق خشک ایران با شبکه عصبی مصنوعی پرداختند. آنها از پارامترهای ورودی رس، شن، سیلت و ماده آلی خاک برای این امر استفاده کردند. نتایج آنها کارایی بالای شبکه MLP که از روش پس انتشارخطا برای آموزش کمک می‌گرفت را نسبت به شبکه GRNN که نوعی از توابع

پایه شعاعی می باشد، را نشان داد. در یک بررسی به مقایسه روش‌های نروفازی، شبکه عصبی (MLP, RBF) و رگرسیون خطی چندگانه در تخمین پتانسیل آماس کانی‌های رسی با بررسی چندین فاکتور آماری پرداخته شد. بر اساس نتایج به دست آمده مدل RBF شبکه عصبی مصنوعی بالاترین قابلیت پیش بینی را دارا بود. پس از آن مدل MLP نسبت به مدل‌های نروفازی و رگرسیون خطی دارای کارایی بالاتری بود (Yilmaz and Kaynar., ۲۰۱۱). سرمردیان و کشاورزی، (۲۰۱۰) از مدل شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره برای پیش‌بینی تعدادی از خصوصیات خاک، استفاده کردند و با اندازه‌گیری پارامترهای ورودی نظیر درصد رس، سیلت و شن، درصد اشباع خاک، وزن مخصوص ظاهری و درصد آهک خاک به تخمین رطوبت نقطه ظرفیت زراعی و نقطه پژمردگی پرداختند. نتایج نشان دهنده کارایی بالای مدل شبکه عصبی با ۵ نرون در لایه پنهان، نسبت به مدل رگرسیونی دارد. سرمردیان و تقی زاده مهرجردی (۲۰۰۸) از مدل‌های شبکه عصبی مصنوعی و رگرسیون خطی برای پیش‌بینی تعدادی از خصوصیات خاک استفاده کردند. نتایج آنها نشان دهنده کارایی بالای مدل شبکه عصبی مصنوعی نسبت به رگرسیون خطی در پیش‌بینی ظرفیت تبادل کاتیونی و رطوبت خاک در نقطه پژمردگی و ظرفیت زراعی بود.

۲-۳- تحقیقات انجام شده بر روی TDR در ایران و جهان

سلطانی محمدی (۱۳۸۴) تاثیر بافت خاک را روی کالیبراسیون TDR در شرایط خاک‌های استان خوزستان بررسی کرد. نتایج حاصل از این تحقیق نشان داد که با افزایش مقدار رس و سنگین‌تر شدن بافت خاک، مدل تاپ رطوبت را کمتر از دستگاه TDR برآورد نموده و در رطوبت‌های بالا بیشتر می‌شود. با افزایش رس در خاک، مدل ترکیبی مقدار رطوبت را بیشتر از روش TDR برآورد نموده و تفاوت مقدار برآوردی با TDR متناظر با افزایش رس، روند رو به رشدی داشته است. در این تحقیق، با مقایسه ضرایب α (پارامتر مربوط به نحوه قرارگیری پروب در خاک) برای مدل ترکیبی در محدوده ۰/۴۵ تا ۰/۶۵ بهترین مقدار برای هر بافت محاسبه شده است. همچنین تحقیقات معروف‌پور و

همکاران (۲۰۰۹) در زمینه تاثیر بافت خاک روی کالیبراسیون دستگاه TDR نشان داد که با افزایش میزان رس، دقت دستگاه در برآورد رطوبت حجمی خاک کاهش می‌یابد. به طوری که با سنگین‌تر شدن بافت خاک دستگاه، رطوبت خاک را کمتر از مقدار واقعی تخمین می‌زند. از دیگر کاربردهای TDR می‌توان به استفاده از آن در مدیریت آب آبیاری در گلخانه جهت کاهش هزینه و افزایش راندمان آبیاری توسط دوستی و بشارت (۱۳۸۵) اشاره کرد. آنها زمان هر آبیاری و کنترل دقیق مدت زمان آبیاری را با استفاده از نصب پروب‌ها و انجام آبیاری در صورتی که سنسورها، رطوبت خاک را کمتر از حد مجاز تشخیص دهند را با روش آبیاری سنتی (بر اساس نمایه ظاهری خاک و گیاه) مقایسه کردند. به طوری که نتایج نشان داد این روش می‌تواند تا حدود زیادی از اتلاف آب جلوگیری کند و باعث افزایش کارایی مصرف آب در گلخانه گردد. در تحقیق دیگری توسط خرسندی و همکاران (۱۳۸۵) در زمینه ساخت و ارزیابی حسگر خازنی اندازه‌گیری رطوبت خاک، تحقیقات خود را در شرایط استاتیکی آزمایشگاه و در خاکی با بافت لومرسی سیلتی انجام دادند. نتایج نشان داد که رابطه بین محتوای رطوبت خاک و فرکانس خروجی حسگر را می‌توان به صورت یک رابطه درجه دو نشان داد. داده‌های خروجی حسگر علاوه بر محتوای رطوبت خاک، به درجه حرارت محیط نیز بستگی دارد. اگرچه بین مقادیر اندازه‌گیری شده توسط حسگر رطوبت و به روش وزنی به علت تاثیر درجه حرارت بر ظرفیت خازنی خاک تفاوت وجود داشت، ولی همبستگی معنی داری ($R^2=0/70$) بین مقادیر اندازه‌گیری شده با این روش مشاهده شد. در تحقیق دیگری توسط کشکولی و ظهرابی (۱۳۸۴) خصوصیات هیدرولیکی غیر اشباع خاک‌های ماسه‌ای از طریق کنترل سطح ایستابی با TDR تعیین شد. اسکندری (۱۳۸۴) با استفاده از TDR، هدایت الکتریکی یک محیط متخلخل را اندازه‌گیری کرد. نتایج نشان داد که اندازه‌گیری هدایت الکتریکی با استفاده از دستگاه TDR و روش متداول، هدایت سنج الکتریکی، برای نمونه‌های آب، از همبستگی بالایی ($R^2=0/96$) برخوردار است. ژاکوبسن و اسپونینگ (۱۹۹۳) در یک تحقیق آزمایشگاهی به منظور کالیبراسیون TDR و تاثیر بافت خاک و چگالی ظاهری روی منحنی کالیبراسیون، از نمونه‌های خاک در ۵ منطقه دانمارک استفاده کردند.

نمونه‌های خاک در محدوده خاک شن تا خاک شن‌رسی لومی با وزن مخصوص ظاهری $1/35 \times 10^3$ تا $1/55 \times 10^3$ کیلوگرم بر مترمکعب بود. در نهایت رابطه درجه سه را بین رطوبت حجمی و ثابت دی‌الکتریک ظاهری برای کالیبراسیون کشف کردند. پرسون و برندتسون (۱۹۹۸) با بررسی اثر دما و بافت خاک روی کالیبراسیون TDR، در سه خاک رسی، آلی و شنی نتیجه گرفتند که در خاک‌های با سطح ویژه زیاد یعنی رس و خاک‌های آلی، اگرچه اثر دما روی کالیبراسیون TDR حداقل است، اما زیاد بودن سطح ویژه و هدایت الکتریکی محلول خاک باعث ایجاد یک فاکتور مثبت و در نتیجه تخمین بیش از مقدار واقعی می‌شود. مالیکی و همکاران (۱۹۹۴) در خاک‌های جنگلی نشان دادند که منحنی تاپ و همکاران (۱۹۸۰) اغلب خطاهای بزرگی را در خاک‌های با ماده آلی داشته که این خطاها به چگالی ظاهری خاک بستگی دارد. راس و همکاران (۱۹۹۲) نیز منحنی کالیبراسیون TDR را برای چندین خاک آلی و معدنی در آزمایشگاه ارائه دادند و بیان داشتند که چگالی ظاهری پارامتر فیزیکی است که رطوبت حجمی خاک‌های آلی را تحت تاثیر قرار می‌دهد.

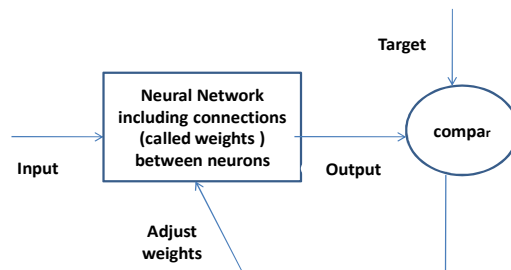
فصل سوم

شبکه‌های عصبی

مصنوعی

۳-۱- آشنایی با شبکه‌های 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 ۳-۱- نمایشی 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 (۳-۱) نمایش داده شده‌است شبکه بر مبنای تطابق و همسنجی بین ورودی و هدف سازگار می‌شود تا اینکه خروجی شبکه و خروجی مورد نظر ما (هدف) بر هم منطبق گردند. عموماً 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.

۳-۲- تاریخچه شبکه عصبی مصنوعی

از قرن نوزدهم به طور همزمان اما جداگانه از سوی 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. در سال ۱۹۶۹ مدل MP شبکه‌های عصبی مصنوعی توسط مک کالوخ و پیت مطرح شد که یک مدل خطی ساده بود، سپس پروسپترون الگوریتم‌های یادگیری را ارائه نمود (منهاج، ۱۳۸۱). سال ۱۹۶۹ آغاز افول موقت شبکه‌های عصبی شد، زیرا عدم توانایی شبکه‌های عصبی در حل مسائل غیرخطی آشکار شد. شبکه‌های عصبی مصنوعی آن زمان فقط قادر به حل مسائلی بودند که می‌شد پاسخ‌های آن مسئله را توسط یک خط در محور مختصات از هم جدا کرد. در سال ۱۹۸۲ هاپفیلد با معرفی شبکه‌های چندلایه و الگوریتم‌های یادگیری دارای Feed back راه حلی برای حل موارد غیرخطی ارائه کرد. در این زمان بود که شبکه‌های بازگشتی، خود سازمانده، (BF (Radial Basis Function، Autoregressive و ... با توجه به این پیشرفت‌های انجام شده در زمینه شبکه عصبی مصنوعی نرم افزارهای زیادی در این زمینه نوشته شده که می‌توان به نرم افزارهای Neuro solution، Nero solution، Qnet۲۰۰۰ و جعبه ابزار شبکه عصبی مصنوعی در Matlab اشاره نمود.

۳-۳- چرا از شبکه‌های عصبی استفاده می‌کنیم.

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

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

۲. خود سازماندهی: یک شبکه عصبی 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. عملگرهای بی‌درنگ: محاسبات در شبکه عصبی مصنوعی می‌تواند به صورت موازی و به وسیله سخت‌افزارهای 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. دسته بندی: شبکه‌های عصبی قادر به دسته بندی ورودی‌ها برای دریافت خروجی مناسب می‌باشند.
۶. تعمیم دهی: این خاصیت شبکه را قادر می‌سازد 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. توانایی که در صورت نبود آن سامانه باید بی‌نهایت واقعیت‌ها و روابط را به خاطر بسپارد.
۷. پایداری- انعطاف پذیری: 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.

۳-۴- ساختار یک سلول شبکه عصبی

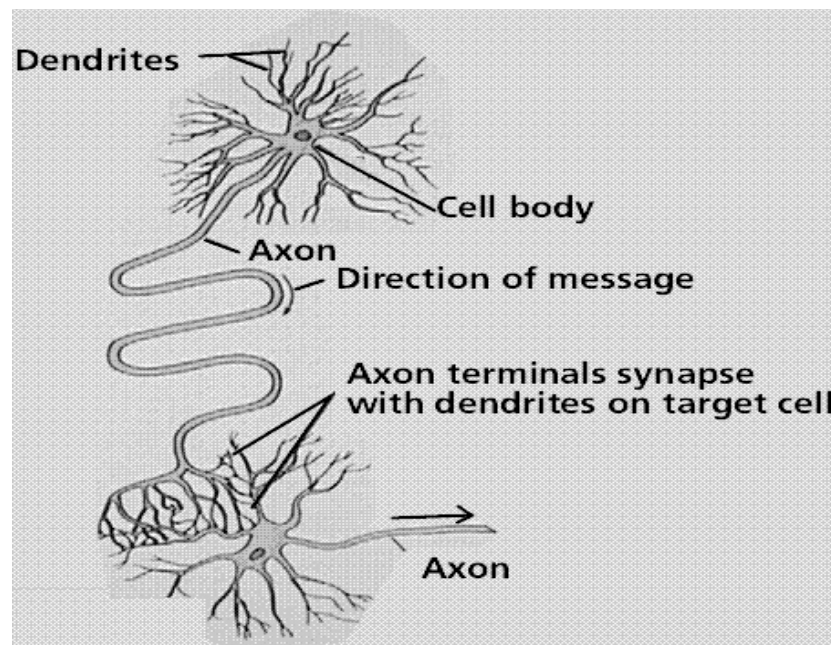
در سیستم عصبی، نرون (سلول عصبی) به عنوان اصلی‌ترین عنصر پردازش شناخته شده است. به طور کلی در بدن انسان در حدود ۱۰۰ تریلیون نرون وجود دارد. که تمام آنها از چهار قسمت اصلی تشکیل شده اند.

۱- بدنه سلول (soma)

۲- دندریت (dendrite)

۳- اکسون (axon)

۴- سیناپس (synops)



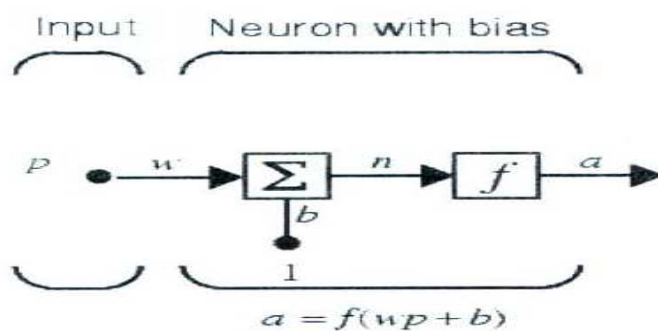
شکل ۲-۳- نرون طبیعی

همان‌طور که از شکل (۲-۳) معلوم است هر نرون دارای تعدادی دندریت و یک اکسون است. دندریت‌ها به عنوان مناطق دریافت سیگنال‌های الکتریکی، شبکه‌های تشکیل یافته از فیبرهای سلولی هستند که دارای سطح نامنظم و شاخه‌های انشعابی بی‌شماری باشند. دندریت‌ها سیگنال‌های الکتریکی را به هسته سلول منتقل می‌کنند. بدنه سلول انرژی لازم را برای فعالیت نرون فراهم کرده و بر روی سیگنال‌های دریافتی عمل می‌کنند، که با یک عمل ساده جمع و مقایسه با یک سطح آستانه مدل می‌گردد. اکسون بر خلاف دندریت‌ها از سطحی هموارتر و تعداد شاخه‌های کمتری برخوردار


می باشد. اکسون طول بیشتری دارد و سیگنال‌های الکتروشیمیایی دریافتی از هسته سلول را به نرون‌های دیگر منتقل می‌کند. محل تلاقی یک اکسون از یک سلول به دندریته‌های سلول‌های دیگر را سیناپس می‌گویند. توسط سیناپس‌ها ارتباطات ما بین نرون‌ها برقرار می‌شود.

۳-۵- ساختار نرون مصنوعی

نرون کوچکترین واحد پردازشگر اطلاعات است، که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. ورودی‌های نرون توسط یک نوع ارتباط به نام وزن به نرون وارد می‌شوند.



شکل ۳-۳- نرون تک لایه با یک ورودی (دموٹ و بیل، ۲۰۰۰)



شکل ۳-۴- نرون تک لایه با R ورودی (دموث و بیل، ۲۰۰۰)

P: ورودی، W: وزن ورودی، b: بایاس، f: تابع تحریک، a: خروجی

بایاس: یک پارامتر قابل تنظیم در نرون‌ها طی روال آموزش می‌باشد و نه یک ورودی.

همان‌طور که در شکل (۳-۴) مشاهده می‌شود نرون مدل سازی شده ورودی‌های خود را محاسبه می‌کند. ابتدا اولین ورودی را در ضریب وزنی مربوط به خط ارتباطی آن ورودی ضرب می‌کند سپس همین عمل را برای ورودی دوم و سایر ورودی‌ها تکرار می‌کند در نهایت تمام مقادیر را جمع می‌کند. در صورتی که مجموع مقادیر از حد آستانه بالاتر رود، نرون تولید خروجی می‌کند (فعال می‌شود).

$$w_i p_i = w_1 p_1 + w_2 p_2 + \dots + w_n p_n \quad (1-3)$$

$$a = f(\sum w_i p_i + b_i) \quad (2-3)$$

b و w دو پارامتر تنظیم شونده در نرون‌ها می‌باشند. ایده اصلی شبکه‌های عصبی این است که با

تغییر مقادیر w و b ، شبکه یک رفتار یا تصمیم را اتخاذ کند. لازم به ذکر است که یک نرون یا یک لایه به تنهایی قابلیت بسیار کم یا ضعیفی دارد ولی از قرار گرفتن تعدادی از آنها در یک لایه و لایه‌ها در کنار هم توانایی بسیار پیچیده‌ای از خود نشان می‌دهد (منهاج، ۱۳۸۱).

۳-۵-۱- لایه

یک لایه از یک یا چند سلول (نرون) تشکیل می‌شود. سلول‌های قرار گرفته در یک لایه دارای تابع آستانه (تابع محرک) یکسان می‌باشند و می‌توان برای هر لایه یک تابع آستانه دلخواه انتخاب کرد. همچنین تابع آموزش برای تمام سلول‌های هر لایه یکسان بوده و می‌توان برای هر لایه‌ای تابع آموزش دلخواه در نظر گرفت. مهمترین خصوصیت سلول‌های یک لایه این است که محاسبات آنها همزمان انجام می‌شود یا به عبارت دیگر ابتدا محاسبات مربوط به یک لایه به طور کامل انجام می‌پذیرد و پس از آن محاسبات لایه بعدی انجام می‌شود که نتایج آن در محاسبات لایه بعد مؤثر خواهد بود. معمولاً لایه‌ای که خروجی آن خروجی نهایی شبکه باشد، به لایه خروجی موسوم است و لایه‌های دیگر، لایه‌های میانی نامیده می‌شوند.

۳-۵-۲- وزن

این ضریب تعیین می‌کند که اهمیت و ارزش اطلاعاتی که به نرون می‌رسد، چقدر است. مسلماً اگر یکی از اطلاعات ورودی اهمیت زیادی در روند یادگیری شبکه داشته باشد. اهمیت و وزن زیادی را به خود اختصاص می‌دهد و برعکس وزن‌ها نیز می‌توانند مقادیری حقیقی و یا دو حالتی باشند اما معمولاً اعداد حقیقی با مقادیر مثبت برای اتصال‌های محرک و مقادیر منفی برای اتصال‌های بازدارنده در نظر گرفته می‌شود.

۳-۵-۳- حافظه

در شبکه‌های عصبی مصنوعی مفهوم حافظه به صورت مقادیر اتصال موجود بین نرون‌ها یا همان

وزن‌ها تعریف می‌شود و آموزش در حقیقت روندی است که در آن وزن بین اتصالات نرون‌ها تغییر می‌کند تا به یک نتیجه مشخص و مطلوب برسد و یادگیری به پایانی در روند آموزش است و در این حالت وزن بین اتصالات تثبیت می‌شود (البرزی، ۱۳۸۹).

۳-۶- توابع محرک

نرون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند. نرم افزار Qnet ۲۰۰۰ 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 کند مقدار تابع به سمت ۰/۵ و هنگامی که مقادیر ورودی به سمت مقادیر مثبت بزرگ میل کند مقدار تابع به سمت یک میل خواهد کرد. فرم این تابع مطابق شکل زیر بوده و به صورت رابطه زیر تعریف می‌شود:


$$f(n) = sig(n) = \frac{1}{1 + e^{-n}} \quad (۳-۳)$$

۳-۶-۱- تابع تحریک تانژانت هایپربولیک

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

$$f(n) = \tanh(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (۴-۳)$$

توابع هایپربولیک قرین با سیگموئید و گوسین، به ترتیب توابع تانژانت هایپربولیک و سکانت هایپربولیک هستند. شکل (۳-۵) رفتار هر تابع را نشان می‌دهد.



شکل ۳-۵- توابع انتقال سیگموئید، گوسین، تانژانت هیپربولیک و سکانت هیپربولیک (راهنمای

نرم افزار Qnet)

۳-۷- تناظر بین شبکه عصبی زیستی و شبکه عصبی مصنوعی

در جدول (۳-۱) تناظر بین شبکه عصبی زیستی و شبکه عصبی مصنوعی آورده شده است.

جدول ۳-۱- تناظر بین شبکه عصبی زیستی و شبکه عصبی مصنوعی

شبکه عصبی مصنوعی	شبکه عصبی زیستی
نورون (<i>Neuron</i>)	سوما (<i>Soma</i>)
ورودی (<i>Input</i>)	دندریت (<i>Dendrite</i>)
خروجی (<i>Output</i>)	آکسون (<i>Axon</i>)
وزن (<i>Weight</i>)	سیناپس (<i>Synapse</i>)

۳-۸- نحوه یادگیری در شبکه های عصبی مصنوعی

یک شبکه عصبی با تعیین رابطه بین ورودی ها (Inputs) و خروجی ها (Outputs) یاد می‌گیرد. این رابطه با محاسبه اهمیت نسبی ورودی‌ها و خروجی‌های سیستم تعیین می‌شود با توجه به آزمون و خطا، سیستم نتایجش را با نتایج داده شده توسط متخصص مقایسه می‌کند، تا زمانی که به سطح مشخصی از دقت برسد. با هر آزمایش وزن ها (Weights) نسبت داده شده به ورودی‌ها تغییر می‌کند تا نتایج مطلوب به دست آید.

۳-۹- مراحل یادگیری:

۱- مقدار دهی اولیه (Initialization): وزن‌های اولیه به تصادف در محدوده موردنظر انتخاب می‌شوند.

۲- فعال سازی (Activation): نرون یا پرسپترون با به کار بردن ورودی‌ها و خروجی‌های مطلوب فعال می‌شوند. (مقدار دهی) خروجی واقعی با تکرار محاسبه می‌شود.

۳- آموزش دادن (Weight Training): وزن‌های نرون یا پرسپترون 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 شبکه‌های عصبی به دو دسته تقسیم می‌شوند. (Anderson, ۱۹۹۵).

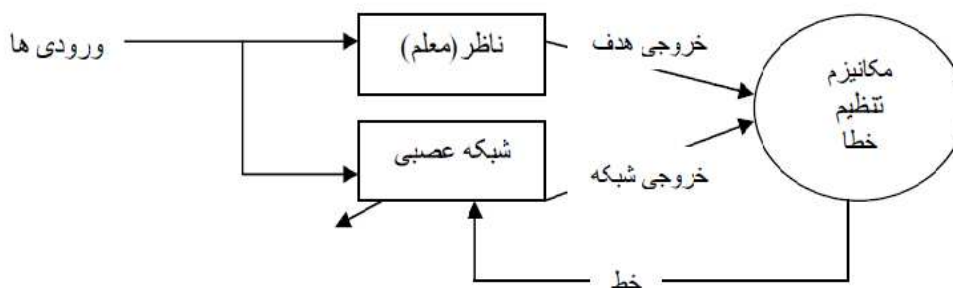
۳-۱۰-۱- یادگیری نظارت نشده یا بدون ناظر

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 موجود 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 موسوم هستند داده می‌شود. هر داده یادگیری شامل ورودی به شبکه و خروجی هدف است. پس از اعمال ورودی به شبکه خروجی شبکه با خروجی هدف مقایسه می‌گردد و سپس خطای یادگیری محاسبه شده و از آن جهت تنظیم پارامترهای شبکه (وزن‌ها) 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 ۳-۶- نمایی از یادگیری نظارت شده یا با ناظر (منهاج، ۱۳۸۱)

۳-۱۱- الگوریتم‌های آموزش

هدف از آموزش شبکه‌های عصبی، یافتن اندازه‌ی وزن‌ها و بایاس‌ها به نحوی است که خطای داده‌های آموزش را به حداقل ممکن برساند. لذا آموزش شبکه‌های عصبی را می‌توان در بردارنده‌ی یک مسئله

بهینه سازی دانست که هدف از آن بهینه سازی ضرایب وزنی و بایاس‌ها جهت دستیابی به حداقل خطای آموزش می‌باشد. به وضوح می‌توان دریافت که تنها یک الگوریتم واحد برای طراحی شبکه عصبی وجود ندارد. ما مجموعه‌ای از ابزارهای ارائه شده برای طیف وسیعی از الگوریتم‌های یادگیری در اختیار داریم که هر کدام از آنها مزایایی خاص خودشان را دارا می‌باشند. تنها تفاوت الگوریتم‌های یادگیری، در روش فرمول‌بندی تنظیم وزن‌های سیناپسی یا پارامترهای شبکه است. در اینجا به توضیح الگوریتم‌های پس‌انتشار خطا می‌پردازیم.

۳-۱۱-۱- الگوریتم پس انتشار خطا

یکی از مهم‌ترین الگوریتم‌های یادگیری شبکه‌های عصبی مصنوعی، قانون یادگیری پس انتشار خطا نامیده می‌شود. یک شبکه عصبی مصنوعی با ساختار پس انتشار خطا از یک لایه ورودی، یک لایه خروجی و حداقل یک لایه میانی تشکیل شده است. در این الگوریتم هر تابع مشتق پذیر و پیوسته‌ای که به طور یکنواخت افزایش یابد، می‌تواند در حکم تابع محرک استفاده شود. معمول‌ترین این توابع، سیگموئیدی، تانژانت هذلولوی و خطی است. انتخاب نوع تابع محرک به هدف مسئله بستگی دارد از قانون یادگیری پس انتشار خطا برای آموزش شبکه‌های عصبی چندلایه پیشخور که عموماً شبکه چندلایه پرسپترون MLP (multi-layer perceptron) نامیده می‌شوند، استفاده می‌کنند قانون پس انتشار خطا از دو مسیر اصلی تشکیل می‌شود. مسیر اول به مسیر رفت (forward path) موسوم است که در آن، بردار ورودی به شبکه اعمال می‌شود و تأثیراتش از راه لایه‌های میانی MLP به لایه‌های خروجی انتشار می‌یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکه MLP را تشکیل می‌دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شوند. و این ثابت و بدون تغییر در نظر گرفتن معمولاً به صورت جمع میانگین مربعات خطا است که به صورت زیر تعریف می‌شود.

$$E = \frac{1}{2} \sum_{i=1}^K (y_{(observed)}^{(i)} - y_{(prediction)}^{(i)})^2 \quad (5-3)$$

مقدار خطا پس از محاسبه، در مسیر برگشت (backward path) از لایه خروجی و از راه لایه میانی شبکه در کل شبکه توزیع می شود. در این مسیر وزن های شبکه MLP مطابق فرمول زیر به گونه ای تغییر می کند و تنظیم می شود، تا مجموع مربعات خطای شبکه کمینه شود.

$$\Delta\omega(t) = -\alpha \frac{\partial E}{\partial \omega(t)} + \beta \Delta\omega(t-1) \quad (6-3)$$

در روابط فوق α و β ثابت هایی در دامنه صفر و یک اند که به ترتیب نرخ یادگیری و تغییرات جزئی وزن شبکه را کنترل می کنند. علاوه بر آن، E تابع خطا ω بردار وزن و t شماره تکرار محاسبات را نشان می دهد.

۳-۱۲- انواع شبکه های عصبی مصنوعی

- پرسپترون چند لایه (Multi-Layer Perceptron)

- شبکه ی هاپفیلد (Hopfield Net)

- نقشه کوهونن (Kohonen Feature Map)

- تئوری رزونانس انطباقی (Theory Adaptive Resonance)

۳-۱۲-۱ پرسپترون

پرسپترون یا Perceptron ساده ترین نوع مدل سازی نرون است. پرسپترون دارای یک سری ورودی

خارجی، یک ورودی داخلی به نام بایاس (bias)، یک آستانه و یک خروجی است. هر پرسپترون نشان دهنده و معرف یک نرون است. ورودی پرسپترون‌ها معمولاً از نوع Boolean است اما در کل می‌تواند هر عددی باشد ولی خروجی همیشه یک Boolean است. در صورتی که خروجی یک پرسپترون یک باشد به آن پرسپترون فعال یا activated می‌گوییم. تمام ورودی‌ها از جمله بایاس دارای یک وزن هستند که این وزن ضرب در مقدار ورودی می‌شود. معمولاً وزن بایاس برابر ۱ است. یکی از مهم‌ترین عوامل هر نرون تابع فعال کننده یا Activation function آن نرون است. تابع فعال کننده تعیین می‌کند که با توجه به ورودی‌های نرون خروجی آن به چه شکل باشد. در پرسپترون‌ها ما یکی از ساده‌ترین توابع فعال کننده را داریم. این تابع تمام ورودی‌های پرسپترون را بعد از ضرب کردن آن‌ها در وزن‌شان با هم جمع می‌کند. در صورتی که جمع آن‌ها از آستانه بیشتر یا مساوی بود خروجی ۱ خواهد بود یعنی پرسپترون فعال خواهد شد و در غیر این صورت پرسپترون غیر فعال خواهد شد. پس در صورتی که شرط زیر برقرار باشد یک پرسپترون فعال خواهیم داشت:

$$W_1X_1+W_2X_2+W_3X_3+\dots+W_nX_n + \geq \Theta \quad (7-3)$$

$W_b b$ در اصل آستانه مانند یک دیوار است اگر سیگنال انرژی کافی برای رد شدن از دیوار را داشته باشد از آن عبور می‌کند در غیر این صورت پشت دیوار می‌ماند.

۳-۱۲-۲- الگوریتم فراگیری پرسپترون ساده

۱- ضرایب و مقادیر اولیه آستانه تعیین می‌شود.

اگر $(0 \leq i \leq n)$ آنگاه $w_i(t)$ را به عنوان ضرایب وزنی ورودی i در زمان Z و θ را به عنوان مقدار آستانه خروجی در نظر گرفته می‌شود. مقدار w_0 را برابر $-\theta$ و مقدار x_0 همیشه برابر ۱ قرار داده می‌شود و مقدار $w_i(0)$ برابر مقادیر تصادفی کوچک است.

۲- ورودی و خروجی مطلوب ارائه گردد.

ورودی‌های $x_0, x_1, x_2, \dots, x_n$ و خروجی مطلوب $d(t)$ به مدل ارائه گردد.

۳- خروجی واقعی محاسبه گردد.

$$y(t) = f_h \left[\sum_{i=0}^n w_i(t) x_i(t) \right] \quad (۸-۳)$$

۴- ضرایب وزنی تبدیل گردد.

اگر خروجی صحیح بود (در این حالت وزن‌ها تغییر نمی‌کند). $w_i(t+1) = w_i(t)$.

اگر خروجی واقعی صفر و خروجی مطلوب ۱ بود (طبقه A). $w_i(t+1) = w_i(t) + x_i(t)$.

اگر خروجی واقعی ۱ و خروجی مطلوب صفر بود (طبقه B). $w_i(t+1) = w_i(t) - x_i(t)$.

این الگوریتم اصلی پرسپترون است. ولی اصلاحاتی در الگوریتم پایه پیشنهاد شد.

یکی از اصلاحات کاهش میزان تغییرات در گام‌های بعدی و تکرارهای متوالی بود. برای این کار ضریب

کوچک و کمتر از یک را به میزان تغییر ضرایب وزنی اضافه کردند که باعث کاهش آهنگ تغییرات

وزن‌ها می‌شود ولی شبکه در تعداد تکرارهای کمتری به جواب نزدیک می‌شود.

۳-۱۲-۳- شبکه پرسپترون چندلایه

شبکه پرسپترون معمولی با تابع آستانه پلکانی از حل مسائلی که غیرخطی باشند ناتوان است و تلاش


برای حل این گونه مسائل توسط پرسپترون، معطوف به افزایش تعداد پرسپترون‌ها شد. ولی افزایش

تعداد پرسپترون‌ها در برخورد با این مسائل باز نتوانست نتیجه مطلوب داشته باشد برای حل این

مشکلات که به سبب پلکانی بودن تابع آستانه پیش آمده بود با تغییر تابع فعالیت و اضافه کردن یک

لایه پنهان مشکلات مربوط به شبکه پرسپترون ساده برطرف گردید. شکل (۷-۳) یک شبکه

پرسپترون چندلایه را نشان می‌دهد.



شکل ۳-۷ نمایی از پرسپترون چند لایه با یک لایه مخفی (حسینی، ۱۳۸۸)

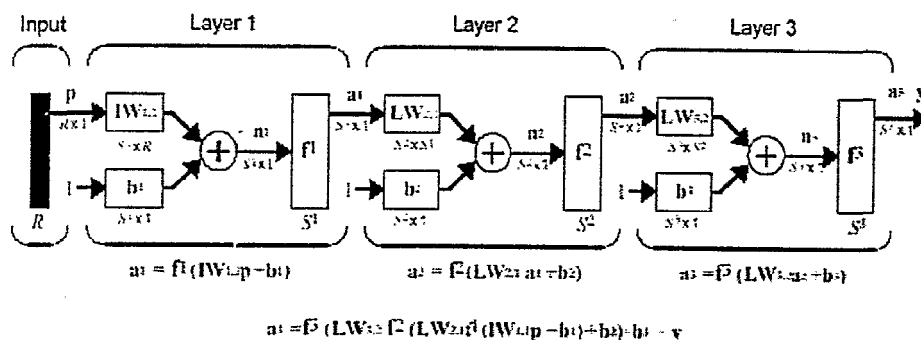
الف) قاعده جدید فراگیری

این قاعده توسط رومل هارت، مک کلند و ویلیامز (۱۹۸۶) پیشنهاد شد و بعدها معلوم شد که نتایج مشابه‌ای نیز قبلاً در سال‌های ۱۹۸۲ توسط پارکر و در سال ۱۹۷۴ توسط روبس گزارش شده است (Widrow, ۱۹۹۰).

قاعده ساده فراگیری پرسپترون تک‌لایه در مورد پرسپترون چندلایه کارگر نیست و قاعده جدید قدمی پیچیده‌تر از قاعده قبلی است. برای موفق شدن در آموزش شبکه باید خروجی آن به تدریج به خروجی مطلوب نزدیک گردد، به عبارت دیگر بایستی میزان تابع خطا کاهش یابد، که کار توسط قاعده دلتا انجام می‌شود و سپس آن را (خطا) به لایه پیشین انتشار می‌دهد (عبارت پس‌انتشار به این علت بدان اطلاق می‌شود).

ب) بیان ریاضی تغییرات در وزن‌ها در روش پس‌انتشار خطا (BP)

شبکه‌ای در نظر گرفته می‌شود که دارای سه لایه است، لایه ورودی (که در آن هیچ پردازشی روی نمی‌دهد)، یک لایه میانی و یک لایه خروجی و تابع فعالیت شبکه از نوع سیگموئید می‌باشد که خروجی شبکه توسط آن محاسبه می‌گردد. شکل (۳-۹) چگونگی این عمل در یک شبکه با ۳ لایه پنهان مشاهده می‌گردد (Demuth and Beale., ۱۹۹۴).



شکل ۳-۹- نمایش از یک شبکه پروسپترون با سه لایه میانی و محاسبه خروجی نهایی (Demuth, ۱۹۹۴)

از آنجایی که مقادیر خطا ابتدا در واحدهای خروجی محاسبه می‌شوند و آن‌گاه به لایه‌های قبلی شبکه (برای تغییر ضرایب وزنی واحدهای پیشین) پس‌رانده می‌شود، این روش در مقالات متعدد به عنوان روش پس‌انتشار خطا (BP) معروف شده است.

با فرض اینکه تابع خطای لایه خروجی برابر باشد با رابطه زیر داریم (Anderson, ۱۹۹۵)

$$E_p = 1/2 \sum_{k=1}^1 (t_k - o_k)^2 \quad (۹-۳)$$

ضریب $\frac{1}{2}$ برای ساده‌تر شدن محاسبات آمده است.

$$net_k = \sum_j w_{jk} o_j \quad (۱۰-۳)$$

$$o_k = f(net_k) \quad (۱۱-۳)$$

با استفاده از قاعده زنجیره‌ای مشتق‌گیری می‌توانیم رابطه (۱۰-۳) را بنویسیم:

$$\frac{\partial E_p}{\partial w_{jk}} = \frac{\partial E_p}{\partial net_k} \frac{\partial net_k}{\partial w_{jk}} \quad (۱۲-۳)$$

که داریم:

$$\frac{\partial net_k}{\partial w_{jk}} = \frac{\partial}{\partial w_{jk}} \sum_j w_{jk} o_j = o_j \quad (۱۳-۳)$$

$$-\frac{\partial E_p}{\partial net_k} = \delta_k \quad (14-3)$$

$$-\frac{\partial E_p}{\partial w_{jk}} = \delta_k o_j \quad (15-3)$$

با استفاده از قاعده مشتق زنجیره‌ای:

$$\delta_k = -\frac{\partial E_p}{\partial net_k} = -\frac{\partial E_p}{\partial o_k} \frac{\partial o_k}{\partial net_k} \quad (16-3)$$

$$\frac{\partial o_k}{\partial net_k} = f'(net_k) \quad (17-3)$$

از رابطه (۷-۳) داریم:

$$\frac{\partial E_p}{\partial o_k} = -(t_k - o_k) \quad (18-3)$$

$$\delta_k = f'(net_k)(t_k - o_k) \quad (19-3)$$

از مزایای استفاده از تابع سیگموئیدی به عنوان تابع غیرخطی پیوستگی، مشتق پذیر بودن و سادگی تابع مشتق آن است که می‌توان برحسب خودش بیان نمود (با تابع اصلی رابطه دارد: ۱۹-۳).

$$y = \text{sgm}(x) = \frac{1}{1 + e^{-net}} \quad (20-3)$$

$$y' = \frac{dy}{dx} = y(1 - y) = \text{sgm}(x)(1 - \text{sgm}(x)) \quad (21-3)$$

پس داریم:

$$o_k = f(net) = \frac{1}{1 + e^{-net}} \quad (22-3)$$

$$f'(net) = \frac{e^{-net}}{(1 + e^{-net})^2} = o_k(1 - o_k) \quad (23-3)$$

از رابطه (۱۹) و (۲۳) داریم: (همانند قاعده دلتا)

$$\delta_k = (t_k - o_k) o_k (1 - o_k) \quad (24-3)$$

و این همان خطایی است که باید به عقب انتشار یابد.

$$\frac{\partial E_p}{\partial w_{jk}} = -(t_k - o_k) o_k (1 - o_k) o_j \quad (25-3)$$

به طور خلاصه تغییر وزن‌ها برای لایه آخر این گونه است:

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = -\eta (-(t_k - o_k) o_k (1 - o_k) o_j) = \eta \delta_k o_j \quad (26-3)$$

تا اینجا مربوط به لایه خارجی بود، چون خروجی‌های مطلوب و خروجی‌های واقعی هر دو معلوم بودند،

ولی چون خروجی‌های مطلوب برای لایه پنهان مشخص نیست بایستی به طریق زیر عمل نمود.

با استفاده از قاعده مشتق زنجیره‌ای:

$$\frac{\partial E_p}{\partial w_{ij}} = \frac{\partial E_p}{\partial net_j} \frac{\partial net_j}{\partial w_{ij}} \quad (27-3)$$

با استفاده از قاعده مشتق زنجیره‌ای:

$$-\delta_j = \frac{\partial E_p}{\partial net_j} = \frac{\partial E_p}{\partial o_j} \frac{\partial o_j}{\partial net_j} \quad (28-3)$$

$$\frac{\partial net_j}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_{i=1}^n x_i w_{ij} = x_i \quad (29-3)$$

$$\frac{\partial o_j}{\partial net_j} = o_j (1 - o_j) \quad (30-3)$$

$$\frac{\partial E_p}{\partial o_j} = \sum_k \frac{\partial E_p}{\partial net_k} \frac{\partial net_k}{\partial o_j} = \sum_k \left(\frac{\partial E}{\partial net_k} \right) \frac{\partial}{\partial o_j} \sum_j w_{jk} o_j = \sum_k \left(\frac{\partial E}{\partial net_k} \right) w_{jk} = -\sum_k \delta_k w_{jk} \quad (31-3)$$

$$\delta_j = o_j (1 - o_j) \sum_k \delta_k w_{jk} \quad (32-3)$$

از جایگزینی (۳۱) و (۲۹) در (۲۷) داریم:

$$\frac{\partial E_p}{\partial w_{ij}} = -\sum_k \delta_k w_{jk} o_j (1 - o_j) x_i \quad (33-3)$$

نهایتاً برای لایه میانی داریم:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \left(-\sum_k \delta_k w_{jk} o_j (1 - o_j) x_i \right) \quad (34-3)$$

$$\Delta w_{ij} = \eta \delta_j x_i \quad (35-3)$$

ج) علت انتخاب تابع سیگموئید

در قاعده پس‌انتشار نیاز مبرم به مشتق‌گیری است. الگوریتم یادگیری شبکه MLP به توابع غیرخطی نیاز دارد که به طور پیوسته قابل مشتق‌گیری باشند تابع سیگموئید به علت داشتن این شرایط و سادگی مشتق آن، انتخاب شده است. از مزایای دیگر آن، شباهت آن به تابع پلکانی است. بنابراین رفتار مشابهی را برایش می‌توان متصور شد. تابع سیگموئید به صورت زیر است:

$$f(net) = \frac{1}{1 + e^{-knet}} \quad (36-3)$$

K عدد ثابتی است که گستره تابع را تنظیم می‌کند. مقادیر بزرگ k تابع را فشرده می‌کند، به طوری که اگر k به سمت بی‌نهایت میل کند تابع به صورت پلکانی در می‌آید.

k همچنین به صورت تنظیم‌کننده خودکار بهره آموزش عمل می‌کند. یعنی در مقادیر کوچک ورودی شیب منحنی بسیار تند شده و بهره آموزش بیشتر می‌شود و در مقادیر ورودی زیاد شیب منحنی کم و بهره آموزش کم می‌شود. این بدان معناست که شبکه می‌تواند ورودی‌های بزرگ را پذیرا باشد و در

همان حال نسبت به تغییرات جزئی حساس باشد (Barlow. ۱۹۸۹).

د) ویژگی‌های مهم شبکه (Multi-Layer Perceptron (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

۵) کاربردهای مهم شبکه MLP

مهم ترین کاربردهای شبکه MLP به شرح زیر است (Fatemi Aghda, ۲۰۰۲).

- ۱- برای شناسایی ویژگی
- ۲- رسته‌بندی و کلاسه‌بندی
- ۳- برای یافتن نگاشت‌های نامعلوم

فصل چهارم

مواد و روشها

۴-۱- روش انجام کار

به منظور انجام تحقیق از داده‌های آزمایشگاهی که بر روی سه بافت سبک، متوسط و سنگین با درصد‌های مختلف ماده آلی (۰/۵، ۲، ۳/۵، ۵، ۶/۵) و در سه تکرار به صورت دست خورده درون گلدان‌هایی به ارتفاع ۲۵/۵ سانتی متر و قطر ۲۵ سانتی متر که توسط مزیدی (۱۳۸۹) اندازه‌گیری شد مورد استفاده قرار گرفت. این پارامترها که عبارتند از: ۱- بافت خاک ۲- درصد ماده آلی ۳- وزن مخصوص حقیقی ۴- وزن مخصوص ظاهری ۵- تخلخل.

برای تعیین بافت خاک از روش هیدرومتری بایکاس، وزن مخصوص ظاهری (P_b) با محاسبه حجم نمونه‌ها در حالت اشباع و وزن خاک (رابطه ۴-۱)، ماده آلی با روش والکلی بلک (Sparks et al., ۱۹۹۶)، وزن مخصوص حقیقی باروش پیکنومتری و تخلخل با استفاده از مقادیر وزن مخصوص ظاهری و حقیقی (رابطه ۴-۲).

$$P_b = \left(\frac{M_s}{V_t} \right) \quad (۴-۱)$$

در رابطه (۴-۱): P_b وزن مخصوص ظاهری، M_s وزن خاک خشک و V_t حجم نمونه‌ها در حالت اشباع می‌باشد.

$$p = 1 - \left(\frac{\rho_b}{\rho_s} \right) \quad (۴-۲)$$

در رابطه (۴-۲): P تخلخل خاک، ρ_b وزن مخصوص ظاهری و ρ_s وزن مخصوص حقیقی خاک بر حسب (gr/cm^3) می‌باشد.

۴-۲- تهیه خاک در سه بافت سبک، متوسط و سنگین

به منظور تهیه بافت سبک، از ترکیب ۴۰ درصد خاک لوم سیلت شنی (شن: ۶۴/۲ درصد، رس: ۲۲/۱۶ درصد و سیلت ۱۳/۶۴ درصد) و ۶۰ درصد شن عبوری از الک شماره ۱۰ که کاملاً شسته شده بود

استفاده گردید. در نهایت بافت سبک (شن: ۷۶/۵۶ درصد، رس: ۹/۴۴ درصد و سیلت ۱۴ درصد) تحت عنوان لوم سیلنتی حاصل شد. همچنین برای تهیه بافت متوسط، از ترکیب ۸۰ درصد از خاک مذکور و ۲۰ درصد از شن شسته شده استفاده گردید و در نهایت خاکی با بافت متوسط (شن: ۵۵/۹۲ درصد، رس: ۱۸/۴۶ درصد و سیلت ۲۵/۶۲ درصد) تحت عنوان لوم حاصل شد. و خاک، با این خصوصیات (شن: ۵۷/۳۶ درصد، رس: ۲۸/۶۴ درصد و سیلت: ۱۴ درصد) در دسته بافت سنگین قرار گرفت.

۳-۴- تهیه ماده آلی

به منظور تهیه ماده آلی از کود لاشبرگ (خاک برگ) استفاده شد. برای تهیه این کود، حجمی از برگ درختان، که توسط گروه باغبانی دانشکده کشاورزی به مدت چند سال انبار شده بود و کاملاً تجزیه شده بودند استفاده شد. علت استفاده از این کود به جای کود حیوانی یا هر نوع کود طبیعی یا شیمیایی دیگر این بود که خاک مورد استفاده در آزمایش باید کاملاً شرایط طبیعی یک خاک زراعی را داشته باشد. بعد از خشک کردن لاشبرگ‌ها، آن را کاملاً خرد نموده و سپس از الک شماره ۱۰ عبور داده شد، تا کاملاً با خاک مورد استفاده همگنی کامل را داشته باشد.

۴-۴- تهیه خاک با درصدهای مختلف ماده آلی

به منظور ایجاد تیمارهای مختلف خاک با درصدهای مختلف ماده آلی، بعد از تعیین درصد ماده آلی با روش والکی بلک، به نسبت‌های وزنی در هر بافت، کود لاشبرگ به دپوی خاک با تیمار مشخص از ماده آلی اضافه شد. از آنجاییکه درصد ماده آلی خاک‌های زراعی در ایران به طور متوسط ۰/۵ درصد و در خاک‌های جنگلی حدود ۷ درصد است. در هر بافت تیمار ماده آلی از ۰/۵ درصد شروع و با اختلاف ۱/۵ درصد، به ۶/۵ درصد ختم می‌شود. بدین ترتیب در هر بافت ۵ تیمار با درصدهای مختلف ماده آلی و در هر تیمار سه تکرار تهیه شد.

۴-۵- تعیین درصد ماده آلی

برای تعیین درصد ماده آلی کود لاشبرگ و خاک، به ترتیب حدود ۰/۲۵ گرم از کود لاشبرگ و ۱ گرم از خاک که از الک شماره ۱۰ عبور داده شده بود، به کمک ۱۰ میلی لیتر دی کرومات پتاسیم و ۲۰ میلی لیتر اسید سولفوریک غلیظ، اکسید شد. سپس با فرسولفات آمونیوم عمل تیتراسیون صورت گرفت. عدد قرائت شده درصد کربن آلی است. نتایج آن در جدول (۴-۱) آورده شده است.

جدول ۴-۱- درصد ماده آلی بافت های مورد مطالعه

بافت	نام خاک	درصد ماده آلی
سبک	لوم شنی	۰/۵
متوسط	لوم	۰/۵
سنگین	لوم رسی شنی	۱
ماده آلی	کود لاشبرگ	۲۳/۵۴

با توجه به اینکه درصد ماده آلی اولین تیمار از بافت سنگین یک درصد است، لازم شد با ترکیب نسبت ۰/۷۸ از خاک لوم شنی عبوری از الک شماره ۱۰ و مانده بر الک ۱۴۰ و ۲۲ درصد از خاک رسی عبوری از الک شماره ۱۰، حاکی با همان درصد ذرات تشکیل دهنده و ۰/۵ درصد ماده آلی ایجاد شود

۴-۶- مراحل انجام کار

بعد از آماده شدن گلدان های حاوی خاک با درصدهای ماده آلی مورد نظر، گلدان ها از کف اشباع

شدند. عمل اشباع کردن گلدان‌ها درون حوضچه‌ای صورت گرفت. بعد از حدود ۲۴ ساعت از اشباع شدن، اندازه‌گیری رطوبت به روش وزنی و با استفاده از TDR به صورت متوالی طی ۱۵، ۱۷ و ۲۱ روز به ترتیب برای بافت سبک، متوسط و سنگین انجام شد و در محاسبات برای به دست آوردن رطوبت حجمی از رابطه :

$$\theta_v = \theta_m * \rho_b \quad (3-4)$$

که در آن θ_v رطوبت حجمی، θ_m رطوبت وزنی، ρ_b وزن مخصوص ظاهری می‌باشد استفاده شد. پارامترهای آماری کمترین، بیشترین، میانگین و انحراف معیار برای ویژگی‌های اندازه‌گیری شده در هر سه نوع بافت خاک در جدول (۲-۴) آورده شده است.

۴-۶-۱-تهیه مدل شبکه عصبی مصنوعی

در این تحقیق از نرم افزار Qnet جهت اجرای مدل شبکه عصبی مصنوعی استفاده گردید. در این راستا پارامترهای اندازه‌گیری شده شامل مقادیر وزن مخصوص ظاهری، مواد آلی، تخلخل و زمان به عنوان داده‌های ورودی به مدل و رطوبت حجمی خاک به عنوان خروجی در هر سه نوع بافت سبک، متوسط و سنگین در نظر گرفته شد. و ۸۰ درصد ترکیب داده‌های ورودی به قسمت آموزش و ۲۰ درصد به قسمت صحت یابی اختصاص داده شدند. توابع انتقال سیگموئید، گوسن، تانژانت هیپربولیک و سکانت هیپربولیک با لایه‌های پنهان متفاوت برای هر سه نوع بافت مورد بررسی قرار گرفتند. برای تعیین دقت توابع از پارامترهای آماری ضریب تبیین (R^2)، میانگین مجذور ریشه خطا (RMSE) و میانگین خطای مطلق (MAE)، استفاده گردید.

۴-۶-۲- استفاده از ثابت دی‌الکتریک خاک برای تعیین رطوبت خاک

اخیراً از خاصیت دی‌الکتریک مواد برای تعیین رطوبت استفاده شده است و بر این اساس دستگاه‌هایی طراحی شده است که با استفاده از خاصیت دی‌الکتریکی خاک، رطوبت را تعیین می‌کنند که

معروف‌ترین آنها روش انعکاس سنجی حوزه زمانی (Time Domain Reflectometry) است که اصطلاحاً، TDR نام گرفته است. استفاده از TDR اخیراً به عنوان روشی مدرن، غیر مخرب و سریع در تعیین رطوبت حجمی خاک شناخته شده است (Jacobsen and Schjonning., ۱۹۹۳).

به کارگیری این روش بر اساس خصوصیات غیر عادی آب یعنی ثابت دی‌الکتریک آن استوار است. به طور کلی دی‌الکتریک به معنای نارسانا بودن الکتریسیته است. یعنی جسمی اگر بین دو سطح باردار قرار گیرد (یک خازن) مانع از تشکیل جریان بار الکتریکی می‌شود. ساده‌ترین شکل خازن دو صفحه فلزی است که بین آنها لایه‌ای از هوا یا ماده عایق دیگری مثل میکا قرار گرفته باشد. بر حسب تعریف ثابت دی‌الکتریک هر ماده که به آن گذرده‌ی نسبی یا ظرفیت القایی ویژه نیز گفته می‌شود، عبارت است از نسبت گنجایش یک خازن که در آن از یک ماده معین به عنوان دی‌الکتریک استفاده شده باشد به گنجایش همان خازن در صورتیکه دی‌الکتریک آن هوا یا خلأ باشد. ثابت دی‌الکتریک یک ماده که غالباً با D یا ϵ نشان داده می‌شود، معیاری برای تمایل مولکول‌های آن ماده جهت آرایش خود در هنگام قرار گرفتن در میدان نیروهای الکتروستاتیک نشان می‌دهد. به دلیل ویژگی خاص آب و اینکه مولکول‌های آب ذرات قطبی می‌باشند، ثابت دی‌الکتریک آن نسبت به سایر مواد بسیار بالاست، لذا ثابت دی‌الکتریک خاک متشکل از سه جزء مایع، گاز و جامد است، عمدتاً توسط مقدار آب کنترل می‌شود. به عبارت دیگر ثابت دی‌الکتریک یک خاک مرطوب بستگی به مقدار رطوبت حجمی دارد و با افزایش رطوبت خاک، ثابت دی‌الکتریک افزایش می‌یابد (بای‌بوردی، ۱۳۷۲).

TDR از دو یا سه میله فلزی تشکیل شده است که معمولاً از جنس مس یا فولاد است که به یک دستگاه گیرنده علائم متصل است. میله‌ها نقش هادی را ایفا می‌کنند و در خاک که به عنوان محیط دی‌الکتریک می‌باشد، فرو برده می‌شوند. تپ‌های ولتاژ الکتریکی در طول میله‌های موازی منتشر شده و سپس از انتهای میله‌ها منعکس می‌شود و به گیرنده دستگاه TDR برگشت داده می‌شوند. به ازای طول ثابت میله، فاصله زمانی بین رفت و برگشت علائم با سرعت انتشار علائم (V) در خاک نسبت عکس دارد. هرکلراس و همکاران (۱۹۹۱) و تاپ (۱۹۹۴) زمان ارسال و برگشت موج الکترومغناطیس

به سمت انتهای موج بر را متناسب با رطوبت حجمی اطراف دانستند. ثابت دی الکتریک بالا (رطوبت حجمی بالا) تاخیر در رسیدن طول موج را افزایش می دهد. از آنجا که ثابت دی الکتریک خاک تابع رطوبت است، تحت تاثیر بافت خاک، چگالی ظاهری، هدایت الکتریکی آب منفذی و دمای خاک می باشد. از این رو می توان بین ϵ و رطوبت حجمی رابطه برقرار کرد.

۴-۶-۲-۱- محاسبه دی الکتریک خاک

انتقال موج الکترومغناطیس در میان خاک به روش انعکاس سنجی حوزه زمان TDR این امکان را می دهد که ثابت دی الکتریک خاک را از طریق معادله تاپ محاسبه کند (Regaldo et al., ۲۰۰۳). مولفه های ثابت دی الکتریک در فرکانس ۱GHZ - ۱MHZ در اکثر خاک های معدنی بین ۳ تا ۱۰ و هوا برابر ۱ و آب برابر ۸۱ است (در دمای ۲۰ درجه) (Anon., ۱۹۸۰). به دلیل اثر متقابل بین خاک و آب شرایط الکتریکی خاک مربوط نسبتا پیچیده است تا جائیکه ثابت دی الکتریک اندازه گرفته شده به رطوبت خاک مرتبط است (Stafford., ۱۹۹۸). در طول هفتاد سال اخیر روی خصوصیات الکترومغناطیسی خاک، مطالعات زیادی انجام گرفته است. خاک از جنبه خصوصیات الکترومغناطیسی به عنوان یک محیط اتلاف کننده انرژی به حساب می آید. ثابت دی الکتریک خاک، بیان کننده توانایی ذرات برای تنظیم کردن خود در یک محیط الکترومغناطیسی القایی می باشد و توسط نسبت بین پتانسیل صفحات باردار در یک ماده نارسانا ϵ بر پتانسیل همان صفحات در خلأ ϵ_0 بیان می شود که می توان آن را با رابطه زیر نشان داد:

$$k = \frac{\epsilon}{\epsilon_0} = \epsilon' \quad (۱۱-۲)$$

در این رابطه k ، ثابت دی الکتریک ذرات و مقدار ϵ برابر $۸/۸۵ \text{ pfm}^{-1}$ می باشد و به قطبش پذیری القایی دی الکتریک مواد و فرکانس زاویه ای بستگی دارد. خاک یک محیط رسانا است که در آن بار الکتریکی کاهش می یابد و با محاسبه این تلفات، میزان دی الکتریک خاک تعیین می شود.

در این تحقیق به منظور مقایسه این دستگاه با شبکه عصبی مصنوعی داده‌های این تحقیق به روش مشابه به دو دسته ۸۰٪ و ۲۰٪ به ترتیب برای مرحله آموزش و صحت‌یابی در هر سه نوع بافت سبک، متوسط و سنگین تفکیک شدند و همانند شبکه عصبی مصنوعی با استفاده از پارامترهای آماری ضریب تبیین، میانگین مجذور ریشه خطا و میانگین خطای مطلق دقت و کارایی روش TDR در تخمین رطوبت حجمی خاک در هر سه نوع بافت خاک مورد بررسی قرار گرفت.

۴-۶-۳- تهیه مدل رگرسیون خطی چند متغیره

رگرسیون روشی برای مدل سازی و تحلیل داده‌های عددی است. رابطه موجود بین سه متغیر یا بیشتر را رگرسیون چند متغیری می‌نامند. در رگرسیون چند متغیری، یک متغیر را وابسته و متغیرهای دیگر را مستقل می‌نامند. هدف از تحلیل رگرسیون، بیان متغیر وابسته به شکل تابعی از متغیر مستقل، ضرایب و مقدارهای خطا است. در رگرسیون خطی چند متغیره با استفاده از روابط خطی میان متغیرهای مستقل با متغیر وابسته به پیش بینی متغیر وابسته می‌پردازیم. در این تحقیق برای اجرای مدل رگرسیون خطی چند متغیره و مقایسه آن با شبکه عصبی مصنوعی، داده‌های این تحقیق به روش مشابه به دو دسته ۸۰٪ و ۲۰٪ به ترتیب برای مرحله آموزش و صحت‌یابی تفکیک شدند. از پارامترهای روز، مواد آلی، وزن مخصوص ظاهری و تخلخل به عنوان متغیرهای مستقل و از پارامتر رطوبت حجمی خاک به عنوان پارامتر وابسته استفاده گردید. برای تعیین رگرسیون چند متغیره پارامترهای مورد مطالعه، رابطه رگرسیونی مربوطه را با استفاده از داده‌های آموزش برای هر سه نوع بافت خاک تعیین کرده سپس داده‌ها در مرحله صحت‌سنجی با استفاده از روابط به دست آمده در مرحله آموزش، مورد بررسی قرار گرفتند. برای تعیین دقت توابع از پارامترهای آماری ضریب تبیین (R^2)، میانگین مجذور ریشه خطا (RMSE) و میانگین خطای مطلق (MAE)، استفاده گردید.

جدول ۴-۲- پارامترهای آماری داده های استفاده شده در سه بافت سبک، متوسط و سنگین

بافت	پارامتر اندازه گیری شده	کمترین	بیشترین	میانگین	انحراف معیار
سبک	روز	۱	۱۵	۸	۴/۳۳
	مواد آلی (درصد)	۰/۵	۶/۵	۳/۵	۲/۱۲۶
	وزن مخصوص ظاهری (gr/cm^3)	۰/۷۸۶	۱/۲۲۱	۱/۰۱۱	۰/۱۲۴
	تخلخل (درصد)	۵۰/۹۱	۶۸/۴۷۲	۵۹/۷۴۷	۴/۶۷۳
	رطوبت حجمی (درصد)	۲/۱۹	۳۴/۵۹	۲۱/۲۴	۶/۲۳
متوسط	روز	۱	۱۷	۹	۴/۹۰۸
	مواد آلی (درصد)	۰/۵	۶/۵	۳/۵	۲/۱۲۶
	وزن مخصوص ظاهری (gr/cm^3)	۰/۷۹۶	۱/۰۷۷	۰/۹۲۹	۰/۰۸۰۶
	تخلخل (درصد)	۶۱/۴۳	۷۰/۲۲۸	۶۵/۴۳۰	۲/۵۱۰
	رطوبت حجمی (درصد)	۱۴/۸۳	۳۶/۷۹	۲۵/۰۹	۴/۹۹۱
سنگین	روز	۱	۲۱	۱۱	۶/۰۶۴
	مواد آلی (درصد)	۰/۵	۶/۵	۳/۵	۲/۱۲۶
	وزن مخصوص ظاهری (gr/cm^3)	۰/۹۰۳	۰/۹۵۷	۰/۹۲۹	۰/۰۱۶۴
	تخلخل (درصد)	۵۵/۶۸	۶۲/۷۹	۵۹/۹۸	۲/۱۵۲
	رطوبت حجمی (درصد)	۱۷/۷۷	۳۸/۵۹	۲۹/۶۵	۵/۷۲

فصل پنجم

نتایج و بحث

۵-۱- مقدمه

در این فصل نتایج حاصل از مدل‌سازی رطوبت حجمی در سه نوع بافت خاک سبک، متوسط و سنگین و مدل‌سازی منحنی‌های زمانی رطوبت حجمی در هر سه نوع بافت که توسط نرم افزار Qnet انجام شده و نتایج حاصل از رگرسیون خطی چند متغیره که با نرم افزار SPSS به دست آمده است و نتایج حاصل از روش TDR ارائه می‌گردد.

۵-۲- پارامترهای ورودی و خروجی

پارامترهای مورد استفاده شامل مقادیر وزن مخصوص ظاهری، مواد آلی، تخلخل و زمان به عنوان داده‌های ورودی به مدل و رطوبت حجمی خاک به عنوان خروجی در نظر گرفته شد. و ۸۰ درصد ترکیب داده‌های ورودی به قسمت آموزش و ۲۰ درصد به قسمت صحت‌یابی اختصاص داده شدند.

۵-۳- اجرای شبکه پرسپترون چند لایه (MLP)

از آنجائیکه در یادگیری شبکه عصبی مصنوعی تعداد لایه‌های میانی و نوع توابع انتقال تاثیر مهمی بر فرآیند یادگیری شبکه‌های عصبی مصنوعی دارند در بخش‌های زیر تاثیر آنها به طور جداگانه مورد بررسی قرار گرفت و سپس بهترین ساختار شبکه عصبی مصنوعی انتخاب گردید.

در ساخت یک مدل بر مبنای شبکه عصبی، اولین کار انتخاب نوع شبکه است. در این تحقیق شبکه عصبی با ساختار پرسپترون چند لایه (MLP) همراه با ناظر که از روش پس انتشار خطا برای آموزش کمک می‌گیرد مورد استفاده قرار گرفته است و دلیل این انتخاب توانایی این نوع شبکه‌ها برای دسته‌بندی (Classification) و کلاسه‌بندی (Clustering) و یافتن نگاشته‌های نامعلوم می‌باشد.

در این شبکه تعداد نرون‌های لایه ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرون‌های لایه خروجی برابر با تعداد عناصر بردار خروجی می‌باشد. و لایه یا لایه‌های پنهان و وظیفه ارتباط لایه‌های

ورودی به لایه‌های خروجی و به‌دست آوردن روابط خطی و غیرخطی را بر عهده دارند (Minansy and McBranteny, ۱۹۹۹).

۵-۳-۱- بررسی تاثیر توابع انتقال در یادگیری شبکه عصبی مصنوعی

توابع انتقال سیگموئید، گوسن، تانژانت هیپربولیک و سکانت هیپربولیک برای هر سه نوع بافت مورد بررسی قرار گرفتند. در بافت سبک تابع انتقال سکانت هیپربولیک با ضریب تبیین (۰/۹۷، ۰/۹۸) به ترتیب برای مراحل آموزش و صحت‌یابی، در بافت متوسط تابع انتقال سکانت هیپربولیک با ضریب تبیین (۰/۹۷، ۰/۹۹) به ترتیب برای مراحل آموزش و صحت‌یابی و در بافت سنگین تابع انتقال سیگموئید با ضریب تبیین (۰/۹۷، ۰/۹۸) به ترتیب برای مراحل آموزش و صحت‌یابی، بهترین کارایی را در تخمین رطوبت حجمی خاک داشته‌اند.

۵-۳-۲- بررسی تاثیر لایه‌های پنهان در یادگیری شبکه عصبی مصنوعی

شکل‌های (۱-۵) تا (۳-۵) منحنی تغییرات RMSE را در لایه‌های پنهان مختلف برای رطوبت حجمی در بافت سبک، متوسط و سنگین نشان می‌دهد. با توجه به شکل‌ها ملاحظه می‌شود بافت سبک با دو لایه پنهان و مقدار $RMSE=0/860$ ، بافت متوسط با دو لایه پنهان و مقدار $RMSE=0/401$ و بافت سنگین با سه لایه پنهان و مقدار $RMSE=0/401$ کمترین خطا را در هر سه بافت نسبت به سایر لایه‌های پنهان نشان دادند، به عنوان بهترین لایه‌های پنهان در ساختار شبکه انتخاب شدند. همان‌طور که در شکل‌ها دیده می‌شود تغییرات RMSE دارای روند مشخصی نمی‌باشد چون شبکه عصبی یک مدل جعبه سیاه می‌باشد و وزن‌ها به طور تصادفی انتخاب می‌شوند نمی‌توان این روند موجود را به طور کامل توضیح داد. فقط باید با سعی و خطا بهترین ساختار را به دست آورد.

۵-۳-۳- 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 سیگموئید، گوسن، تانژانت هیپربولیک و سکانت هیپربولیک

استفاده گردید. برای اجرای مدل، داده‌ها به صورت ۸۰٪ و ۲۰٪ به ترتیب برای مرحله آموزش و صحت‌یابی تفکیک شدند. 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 (۱-۵)، (۲-۵) و (۳-۵) استفاده گردید.

$$R^2 = \frac{\sum(x-\bar{x})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}} \quad (1-5)$$

$$RMSE = \sqrt{1/n \sum_{i=1}^n (X_o - X_p)^2} \quad (2-5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_o - \widehat{X_p}| \quad (3-5)$$

که در آنها: X مقادیر پیش‌بینی شده، $\widehat{X_p}$ و X_p مقادیر مشاهداتی و n تعداد داده‌ها می‌باشد همچنین \bar{y} و \bar{x} به ترتیب مقدار مطلق و متوسط مقادیر خروجی شبکه عصبی و X و \bar{x} به ترتیب برابر مقادیر مطلق و متوسط رطوبت حجمی اندازه‌گیری شده است.


با توجه به جدول (۱-۵) نتایج اجرای مدل نشان می‌دهد که تابع محرک سکانت هیپربولیک با دو لایه پنهان و داشتن ضریب تبیین (۰/۹۸، ۰/۹۷) به ترتیب برای مراحل آموزش و صحت‌یابی رطوبت حجمی در بافت سبک، تابع محرک سکانت هیپربولیک با دو لایه پنهان و داشتن ضریب تبیین (۰/۹۷، ۰/۹۹) به ترتیب برای مراحل آموزش و صحت‌یابی رطوبت حجمی در بافت متوسط و تابع محرک سیگموئید با سه لایه پنهان و داشتن ضریب تبیین (۰/۹۸، ۰/۹۷) به ترتیب برای مراحل آموزش و صحت‌یابی رطوبت حجمی در بافت سنگین دارای نتایج بهتری نسبت به سایر توابع می‌باشد. جدول (۱-۵) نتایج حاصل از اجرای مدل MLP و بهترین توابع ذکر شده برای تخمین رطوبت حجمی در سه بافت سبک، متوسط و سنگین را نشان می‌دهد. نتایج حاصل از اجرای تعداد لایه‌های پنهان مختلف و توابع مختلف در تخمین رطوبت حجمی در سه بافت سبک، متوسط و سنگین در پیوست

شماره (۱) الی (۳) آمده است. علاوه بر پارامتر ضریب تبیین (R^2) که بیشترین مقدار را دارد، پارامترهای RMSE و MAE نیز مقادیر کمتری را در سه تابع محرک ذکر شده نشان می‌دهند. که نشان از قابلیت بالای این توابع در تخمین رطوبت حجمی دارد. زیرا اتکا به پارامتر ضریب تبیین برای بررسی قابلیت های مختلف هر شبکه و تابع، کافی نبوده و نیاز به مطالعات گسترده تر آماری وجود دارد. در شکل‌های (۴-۵) الی (۹-۵) پراکنش داده های اندازه‌گیری شده و پیش‌بینی شده برای رطوبت حجمی سه نوع بافت خاک برای شبکه MLP آورده شده است.


جدول ۵-۱- نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین رطوبت حجمی در سه نوع بافت سبک، متوسط و

سنگین


MAE	RMSE	ضریب تبیین (R^2)	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۶۳۲	۰/۸۰۴	۰/۹۸	آموزش		سکانت	
۰/۶۸۵	۰/۸۶۰	۰/۹۷	صحت یابی	۲	هیپربولیک Secant Hyperbolic	سبک
۰/۴۴۸	۰/۶۲۰	۰/۹۷	آموزش		سکانت	
۰/۳۱۲	۰/۴۰۱	۰/۹۹	صحت یابی	۲	هیپربولیک Secant Hyperbolic	متوسط
۰/۵۸۰	۰/۸۰۲	۰/۹۸	آموزش		سکانت	
۰/۵۵۱	۰/۷۸۵	۰/۹۷	صحت یابی	۳	سیگموئید Sigmoid	سنگین




شکل ۵-۱- مقادیر RMSE لایه‌های پنهان متفاوت برای رطوبت حجمی خاک سبک




شکل ۵-۲- مقادیر RMSE لایه‌های پنهان متفاوت برای رطوبت حجمی خاک متوسط




شکل ۵-۳- مقادیر RMSE لایه‌های پنهان متفاوت برای رطوبت حجمی خاک سنگین




شکل ۵-۴- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله آموزش در بافت سبک




شکل ۵-۵- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله صحت‌یابی در بافت سبک




شکل ۵-۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله آموزش در بافت متوسط



شکل ۵-۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله صحت‌یابی در بافت متوسط



شکل ۵-۸- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله آموزش در بافت سنگین



شکل ۵-۹- نمودار پراکنش داده‌گیری اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی در بافت سنگین


۴-۵- تخمین زمانی رطوبت حجمی در سه نوع بافت خاک با شبکه عصبی مصنوعی

داده‌های اندازه‌گیری شده برای هر بافت را که برای بافت سبک، متوسط و سنگین به ترتیب رطوبت حجمی را طی ۱۵، ۱۷ و ۲۱ روز اندازه‌گیری انجام شده بود به عنوان خروجی و پارامترهای زمان، مواد آلی، وزن مخصوص ظاهری و تخلخل را به عنوان ورودی به شبکه عصبی مصنوعی مورد استفاده قرار دادیم. و با استفاده از پارامترهای آماری ضریب تبیین، میانگین مجذور ریشه خطا و میانگین خطای مطلق، دقت و کارایی شبکه عصبی در تخمین زمانی رطوبت حجمی مورد بررسی قرار گرفت. جدول (۲-۵) نتایج حاصل از اجرای مدل را در تخمین زمانی رطوبت حجمی در سه نوع بافت خاک را نشان می‌دهد. همان‌طور که مشاهده می‌شود تابع محرک سیگموئید با ۱ لایه پنهان و ضریب تبیین ۰/۹۸، ۰/۹۷ به ترتیب برای مرحله آموزش و صحت‌یابی در بافت سبک، تابع محرک سکانت هیپربولیک با ۳ لایه پنهان و ضریب تبیین ۰/۹۸، ۰/۹۸ به ترتیب برای مرحله آموزش و صحت‌یابی در بافت متوسط و تابع محرک سیگموئید با دو لایه پنهان و ضریب تبیین ۰/۹۶، ۰/۹۷ به ترتیب برای مرحله آموزش و صحت‌یابی در بافت سنگین بهترین پیش‌بینی زمانی رطوبت حجمی را در هر سه بافت انجام داده‌اند.


در شکل‌های (۵-۱۰) الی (۵-۱۲) نمودارهای تخمین زمانی رطوبت حجمی خاک در هر سه نوع بافت آورده شده است.

جدول ۵-۲- نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین زمانی رطوبت حجمی در سه نوع بافت خاک


بافت	تعداد لایه پنهان	تابع محرک	مرحله محاسباتی	ضریب تبیین (R^2)	RMSE	MAE
سبک	۱	سیگموئید	آموزش	۰/۹۸	۱/۵۶۳	۱/۴۱۲
		Sigmoid	صحت‌یابی	۰/۹۷	۱/۷۸۳	۱/۵۱۰
متوسط	۱	سکانت	آموزش	۰/۹۸	۱/۷۸۵	۱/۵۹۶
		هیپر بولیک	صحت‌یابی	۰/۹۸	۱/۸۸۶	۱/۶۱۶
		Secant Hyperbolic	صحت‌یابی	۰/۹۸	۱/۸۸۶	۱/۶۱۶
سنگین	۲	سیگموئید	آموزش	۰/۹۶	۱/۰۵۹	۰/۶۸۵
		Sigmoid	صحت‌یابی	۰/۹۷	۱/۱۰۸	۰/۷۱۶



شکل ۵-۱۰- پیش بینی منحنی زمانی رطوبت حجمی خاک در بافت سبک (مرحله صحت‌یابی)



شکل ۵-۱۱- پیش بینی منحنی زمانی رطوبت حجمی خاک در بافت متوسط (مرحله صحت یابی)

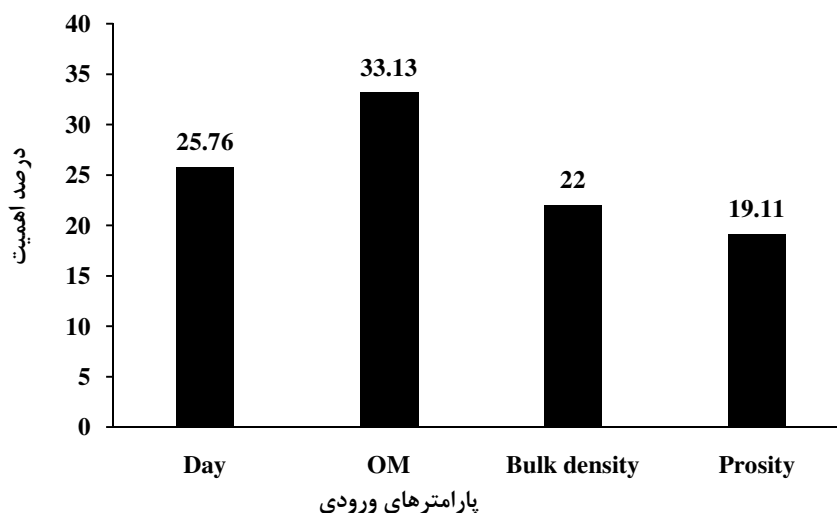


شکل ۵-۱۲- پیش بینی منحنی زمانی رطوبت حجمی خاک در بافت سنگین (مرحله صحت یابی)


۵-۵- اهمیت پارامترهای ورودی به مدل شبکه عصبی مصنوعی

پس از اجرای مدل شبکه عصبی، میزان اهمیت پارامترهای ورودی به شبکه در برآورد رطوبت حجمی خاک در هر سه نوع بافت سبک، متوسط و سنگین بررسی گردید. نتایج اهمیت هر پارامتر بر حسب

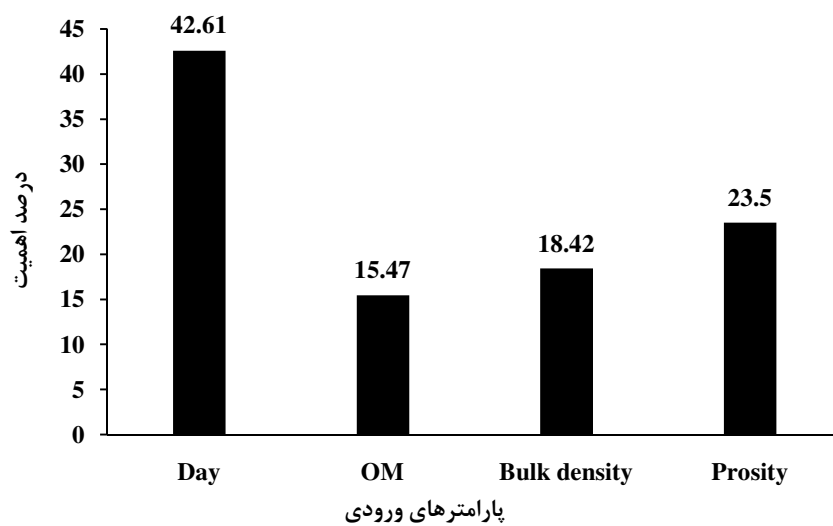
درصد مشارکت در ایجاد مدل شبکه عصبی مصنوعی که توسط Qnet محاسبه می‌شود در شکل‌های (۱۳-۵) الی (۱۵-۵) آمده است. همان‌طوری که در شکل (۵-۱۳) دیده می‌شود در بافت سبک بیشترین مشارکت و اهمیت را پارامتر مواد آلی با مقدار ۳۳/۱۳ درصد دارد. می‌توان نتیجه گرفت که هرچه بافت سبک‌تر می‌شود نقش ماده آلی در نگهداری رطوبت خاک بیشتر احساس می‌شود. و در بافت سنگین (شکل ۵-۱۵) بیشترین مشارکت و اهمیت را پارامتر روز با مقدار ۴۲/۶۱ درصد دارد زیرا خاک‌های سنگین بافت رطوبت حجمی را بیشتر از خاک‌های با بافت متوسط و سبک در خود ذخیره می‌کنند و در نتیجه رطوبت خود را طی زمان طولانی‌تری نسبت خاک‌های با بافت سبک و متوسط از دست می‌دهند و به همین علت پارامتر روز اهمیت بیشتری داشته است. در بافت متوسط همانند بافت سنگین اهمیت و مشارکت پارامتر روز بیشتر احساس می‌شود.



شکل ۵-۱۳- سهم پارامترهای ورودی در تخمین رطوبت حجمی خاک در بافت سبک



شکل ۵-۱۴- سهم پارامترهای ورودی در تخمین رطوبت حجمی خاک در بافت متوسط




شکل ۵-۱۵- سهم پارامترهای ورودی در تخمین رطوبت حجمی خاک در بافت سنگین

۵-۶- برآورد رطوبت حجمی در سه نوع بافت خاک با استفاده از TDR

همان‌طور که قبلاً گفته شد یکی از ابزارهای غیر مستقیم اندازه‌گیری رطوبت خاک استفاده از دستگاه TDR می‌باشد. در این تحقیق به منظور مقایسه این دستگاه با شبکه عصبی مصنوعی داده‌های این تحقیق به روش مشابه در هر سه نوع بافت خاک به دو دسته ۸۰٪ و ۲۰٪ به ترتیب به دیتای آموزش و صحت‌یابی تفکیک شدند. با استفاده از پارامترهای آماری ضریب تبیین، میانگین مجذور ریشه خطا و میانگین خطای مطلق، دقت و کارایی روش TDR در هر سه نوع بافت خاک مورد بررسی قرار گرفت. جدول (۳-۵) نتایج حاصل از اجرای روش TDR برای تخمین رطوبت حجمی در سه نوع بافت خاک را نشان می‌دهد. همان‌طور که مشاهده می‌شود TDR در بافت سبک با ضریب تبیین (۰/۸۳، ۰/۶۶) به ترتیب برای داده‌های آموزش و صحت‌یابی، در بافت متوسط با ضریب تبیین (۰/۸۲، ۰/۸۶) به ترتیب برای داده‌های آموزش و صحت‌یابی و در بافت سنگین با ضریب تبیین (۰/۸۴، ۰/۸۶) رطوبت حجمی را تخمین زده است. در شکل‌های (۱۳-۵) الی (۱۸-۵) پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای رطوبت حجمی در سه نوع بافت خاک آورده شده است.


جدول ۳-۵- نتایج حاصل از اجرای روش TDR برای تخمین رطوبت حجمی در سه نوع بافت سبک، متوسط و سنگین

بافت	مرحله محاسباتی	ضریب تبیین (R ^۲)	RMSE	MAE
سبک	آموزش	۰/۶۶	۳/۶۰۱	۲/۴۲۷
	صحت‌یابی	۰/۸۳	۲/۲۶۱	۱/۸۷۲
متوسط	آموزش	۰/۸۲	۲/۴۲۵	۱/۸۲۵
	صحت‌یابی	۰/۸۶	۱/۹۱۰	۱/۵۲۷
سنگین	آموزش	۰/۸۴	۱/۹۵۸	۱/۳۷
	صحت‌یابی	۰/۸۶	۲/۰۱۱	۱/۳۸۳




۵-۱۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های آموزش به وسیله دستگاه

TDR برای بافت سبک




۵-۱۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های صحت‌یابی به وسیله دستگاه TDR


برای بافت سبک




۱۸-۵- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های آموزش به وسیله دستگاه TDR برای بافت متوسط



شکل ۵-۱۹- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده با استفاده از داده‌های صحت‌یابی به وسیله دستگاه TDR برای بافت متوسط



۵- ۲۰- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده با استفاده از داده‌های آموزش به وسیله دستگاه TDR برای بافت سنگین



۵- ۲۱- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده با استفاده از داده‌های صحت‌یابی به وسیله دستگاه TDR برای بافت سنگین

۵-۷- اجرای مدل رگرسیون خطی چند متغیره

برای تعیین رگرسیون چند متغیره پارامترهای مورد مطالعه، مقایسه آن با شبکه عصبی مصنوعی و TDR داده‌ها به روش مشابه به دو دسته ۸۰٪ و ۲۰٪ به ترتیب به دیتای آموزش و صحت‌یابی تفکیک شدند. رابطه رگرسیونی مربوطه را با استفاده از داده های آموزش تعیین کرده که به صورت روابط (۴-۵)، (۵-۵) و (۶-۵) برای رطوبت حجمی سه نوع بافت خاک سبک، متوسط و سنگین می‌باشد. سپس داده‌ها در مرحله صحت‌سنجی با استفاده از روابط به دست آمده در مرحله آموزش، مورد بررسی قرار گرفتند. برای اجرای مدل از پارامترهای روز، مواد آلی، وزن مخصوص ظاهری و تخلخل به عنوان متغیرهای مستقل و از پارامتر رطوبت حجمی خاک به عنوان پارامتر وابسته استفاده گردید. برای تعیین دقت توابع از پارامترهای آماری ضریب تبیین (R^2)، میانگین مجذور ریشه خطا (RMSE) و میانگین خطای مطلق (MAE)، استفاده گردید

$$R^2 = 0.83 \quad (4-5)$$

$$R^2 = 0.86 \quad (5-5)$$


$$R^2 = 0.90 \quad (6-5)$$

در جدول (۴-۵) نتایج حاصل از اجرای مدل رگرسیونی برای رطوبت حجمی سه نوع بافت سبک، متوسط و سنگین آورده شده است. همان‌طور که مشاهده می‌شود مدل رگرسیون با R^2 ، RMSE و MAE (۰/۸۵، ۲/۲۵۶، ۱/۶۴۷) برای داده‌های صحت‌یابی در بافت سبک، (۰/۹۰، ۱/۵۹۶، ۱/۱۱۵) برای داده‌های صحت‌یابی در بافت متوسط و (۰/۸۸، ۱/۵۱۷، ۱/۰۰۵) برای داده‌های صحت‌یابی در بافت سنگین رطوبت حجمی را تخمین زده است. که حاکی از دقت پایین و خطای بالا در تخمین


رطوبت حجمی خاک می‌باشد. در شکل های (۵-۱۹) الی (۵-۲۴) پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای رطوبت حجمی در هر سه نوع بافت خاک برای مدل رگرسیون خطی چند متغیره آورده شده است.

جدول ۵-۴- نتایج حاصل از اجرای مدل رگرسیونی خطی چند متغیره برای تخمین رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین

بافت	مرحله محاسباتی	ضریب تبیین (R^2)	RMSE	MAE
سبک	آموزش	۰/۸۳	۲/۶۱۵	۲/۱۱۸
	صحت‌یابی	۰/۸۵	۲/۲۵۶	۱/۶۴۷
متوسط	آموزش	۰/۸۶	۱/۶۹۶	۱/۰۸۴
	صحت‌یابی	۰/۹۰	۱/۵۹۶	۱/۱۱۵
سنگین	آموزش	۰/۹۰	۱/۵۴۱	۱/۰۲۵
	صحت‌یابی	۰/۸۸	۱/۵۱۷	۱/۰۰۵




شکل ۵-۲۲- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله آموزش مدل رگرسیون در بافت سبک




شکل ۵-۲۳- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله صحت‌یابی مدل رگرسیون در بافت


سبک




شکل ۵-۲۴- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله آموزش مدل رگرسیونی در بافت متوسط



شکل ۵-۲۵- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش بینی شده برای مرحله صحت‌یابی مدل رگرسیون در بافت متوسط



شکل ۵-۲۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله آموزش مدل رگرسیونی در بافت سنگین



شکل ۵-۲۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله صحت‌یابی مدل رگرسیونی در بافت سنگین

فصل ششم

نتیجه‌گیری و

پیشنهاداتها

۶-۱- نتیجه‌گیری

در این پژوهش به منظور پیش‌بینی رطوبت حجمی در سه نوع بافت سبک، متوسط و سنگین از روش شبکه عصبی مصنوعی (MLP) رگرسیون چند متغیره خطی و TDR استفاده گردید. برای مدل سازی با شبکه عصبی مصنوعی از نرم افزار QNET و به منظور انجام مدل رگرسیون خطی چند متغیره از نرم افزار SPSS استفاده شد.

به دلیل وجود سه نوع بافت مختلف، با تیمارهای مختلف ماده آلی (۰/۵، ۲، ۳/۵، ۵، ۶/۵) مدل‌های پیش‌بینی شده رطوبت حجمی خاک توسط شبکه عصبی مصنوعی قابلیت تعمیم به خاک‌های سایر مناطق با درصد‌های مختلف ماده آلی را دارد و با توجه به پیش‌بینی زمانی رطوبت حجمی در این سه نوع بافت می‌توان مدل را برای مناطق مختلف برای پیش‌بینی مقدار رطوبت حجمی خاک در هر روز تعمیم داد.

با توجه به معیارهای آماری حداقل ریشه میانگین مجذور خطا (RMSE) و میانگین خطای مطلق (MAE) و ضریب تبیین (R^2) و مقایسه نتایج مدل‌ها، بهترین ساختار برای پیش‌بینی رطوبت حجمی انتخاب شد. در ذیل مهم‌ترین نتایج حاصل از این تحقیق به اختصار و به تفکیک شبکه‌های مورد استفاده آورده شده است.

۶-۱-۱- شبکه پرسپترون چند لایه (MLP)

در مدل‌سازی با شبکه عصبی مصنوعی برای هر سه نوع بافت خاک سبک، متوسط و سنگین از شبکه عصبی پرسپترون چند لایه استفاده گردید. نخست با معرفی ۸۰٪ داده‌های جمع‌آوری شده برای مرحله آموزش به نرم افزار Qnet، شبکه طراحی شد. توابع محرک سیگموئید، گوسن، تانژانت هیپربولیک و سکانت هیپربولیک به طور جداگانه، هریک برای اجرای مدل انتخاب شدند. بنابراین در این شبکه طراحی شده، مدل‌سازی با تمام توابع صورت گرفت و شبکه برای محاسبه رطوبت حجمی با توجه به ۸۰٪ داده‌ها آموزش داده شد. میانگین مجذور ریشه خطا، ضریب تبیین و خطای مطلق برای مرحله

آموزش حاصل گردید و سپس در مرحله صحت‌سنجی ۲۰٪ مابقی داده‌ها به شبکه معرفی گردید و شبکه با توجه به مرحله آموزش به پیش‌بینی داده‌هایی پرداخت که برای شبکه شناخته شده نبود. معیارهای مقایسه در مرحله صحت‌سنجی با معیارهای مرحله آموزش برای تمامی شبکه‌ها با توابع محرک گوناگون و لایه‌های پنهان متفاوت مقایسه گردید. برای بافت سبک شبکه طراحی شده با دو لایه پنهان و تابع محرک سکانت هیپربولیک، بافت متوسط همانند بافت سبک با دو لایه پنهان و تابع محرک سکانت هیپربولیک و بافت سنگین با سه لایه پنهان و تابع محرک سیگموئید به عنوان بهترین شبکه طراحی شده برای پیش‌بینی رطوبت حجمی انتخاب شدند.

۶-۱-۲- مقایسه مدل شبکه عصبی مصنوعی (MLP)، مدل رگرسیون خطی

چند متغیره و TDR

نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی، رگرسیون خطی چند متغیره و TDR برای تخمین رطوبت حجمی در هر سه نوع بافت خاک در جدول (۶-۱) آورده شده است. نتایج این بررسی نشان می‌دهد مدل شبکه عصبی مصنوعی به ترتیب با R^2 ، RMSE و MAE (۰/۹۷، ۰/۸۶۰، ۰/۶۸۵) برای مرحله صحت‌یابی در بافت سبک، (۰/۹۹، ۰/۴۰۱، ۰/۳۱۲) برای مرحله صحت‌یابی در بافت متوسط و (۰/۹۷، ۰/۷۸۵، ۰/۵۵۱) برای مرحله صحت‌یابی در بافت سنگین قابلیت بالایی را در تخمین رطوبت حجمی در هر سه نوع بافت خاک را دارد و نسبت به روش رگرسیون خطی چند متغیره که به ترتیب با R^2 ، RMSE و MAE (۰/۸۵، ۲/۲۵۶، ۱/۶۴۷) برای داده‌های صحت‌یابی در بافت سبک، (۰/۹۰، ۱/۹۶، ۱/۱۱۵) برای داده‌های صحت‌یابی در بافت متوسط و (۰/۸۸، ۱/۵۱۷، ۱/۰۰۵) برای داده‌های صحت‌یابی در بافت سنگین رطوبت حجمی را تخمین زده است و همچنین نسبت به TDR که به ترتیب با R^2 ، RMSE و MAE (۰/۸۳، ۲/۹۳۳، ۲/۱۴۰) برای داده‌های صحت‌یابی در بافت سبک، (۰/۸۶، ۱/۹۱۰، ۱/۵۲۷) برای داده‌های صحت‌یابی در بافت متوسط و (۰/۸۶، ۱/۹۵۸، ۱/۳۳۷) برای داده‌های صحت‌یابی در بافت سنگین رطوبت حجمی را تخمین زده است. بالاترین دقت و

کمترین میزان خطا (بیشترین ضریب تبیین و کمترین مقادیر RMSE و MAE) را در تخمین رطوبت حجمی خاک در هر سه نوع بافت خاک دارد. نتایج حاصل از TDR که نشان دهنده دقت کمتر و میزان خطای بیشتر در تخمین رطوبت حجمی در هر سه نوع بافت خاک نسبت به شبکه عصبی مصنوعی و رگرسیون چند متغیره می باشد حاکی از این است که دستگاه TDR برای تخمین رطوبت حجمی در سه نوع بافت خاک با درصدهای مختلف مواد آلی (۰/۵، ۲، ۳/۵، ۵، ۶/۵) باید کالیبره شود و با توجه به تاثیر بافت و مواد آلی بر روی منحنی کالیبراسیونی مقدار رطوبت حجمی خاک را برآورد نمود.

جدول ۶-۱- نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی، رگرسیون خطی چند متغیره و TDR برای تخمین

رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین

مدل	بافت	مرحله محاسباتی	R ^۲	RMSE	MAE	
MLP	سبک	آموزش	۰/۹۸	۰/۸۰۴	۰/۶۳۲	
		صحت‌یابی	۰/۹۷	۰/۸۶۰	۰/۶۸۵	
	متوسط	آموزش	۰/۹۷	۰/۶۲۰	۰/۴۴۸	
		صحت‌یابی	۰/۹۹	۰/۴۰۱	۰/۳۱۲	
	سنگین	آموزش	۰/۹۸	۰/۸۰۲	۰/۵۸۰	
		صحت‌یابی	۰/۹۷	۰/۷۸۵	۰/۵۵۱	
TDR	سبک	آموزش	۰/۶۶	۳/۶۰۱	۲/۴۲۷	
		صحت‌یابی	۰/۸۳	۲/۹۳۳	۲/۱۴۰	
	متوسط	آموزش	۰/۸۲	۲/۴۲۵	۱/۸۲۵	
		صحت‌یابی	۰/۸۶	۱/۹۱۰	۱/۵۲۷	
	سنگین	آموزش	۰/۸۴	۱/۹۵۸	۱/۳۷	
		صحت‌یابی	۰/۸۶	۲/۰۱۱	۱/۳۸۳	
	رگرسیون چند متغیره خطی	سبک	آموزش	۰/۸۳	۲/۶۱۵	۲/۱۱۸
			صحت‌یابی	۰/۸۵	۲/۲۵۶	۱/۶۴۷
		متوسط	آموزش	۰/۸۶	۱/۶۹۶	۱/۰۸۴
			صحت‌یابی	۰/۹۰	۱/۵۹۶	۱/۱۱۵
		سنگین	آموزش	۰/۹۰	۱/۵۴۱	۱/۰۲۵
			صحت‌یابی	۰/۸۸	۱/۵۱۷	۱/۰۰۵

۶-۲- پیشنهادها

- استفاده از سایر مدل‌های شبکه عصبی نظیر مدل (RBF و GFF) و بررسی قابلیت آنها در تخمین رطوبت حجمی خاک.
- بررسی مدل الگوریتم ژنتیک (GA)، برنامه ریزی ژن (EPG) و نروفازی (ANFIS) در تخمین رطوبت حجمی خاک و بررسی نتایج آنها.
- استفاده از فاکتورهای آماری بیشتری نظیر برتری نسبی (RI) و خطای استاندارد (SE)، برای تعیین دقت مدل و میزان خطای اعداد پیش بینی شده نسبت به اعداد اندازه‌گیری شده در تخمین رطوبت حجمی خاک.

منابع مورد استفاده

۱. البرزی م، (۱۳۸۹)، "آشنایی با شبکه‌های عصبی"، انتشارات دانشگاه صنعتی شریف.
۲. امامی ح، نیشابوری م، شرفاء م و لیاقت ع، (۱۳۸۶)، "ارزیابی کارایی شبکه‌های عصبی مصنوعی در برآورد منحنی رطوبتی خاک در بعضی از خاکهای آهکی و شور ایران"، دهمین کنگره علوم خاک ایران، کرج.
۳. اسکندری ذ. ا، و بهمن‌پور، (۱۳۸۴) "تعیین هدایت الکتریکی آب و خاک با استفاده از TDR" ص ۱۸۱-۱۸۳، مجموعه مقالات فیزیک و روابط خاک، آب و گیاه.
۴. بای‌بوردی م، (۱۳۷۲) "روابط آب و خاک" جلد اول، چاپ ششم، انتشارات دانشگاه تهران، دانشگاه تهران.
۵. جعفری حقیقی م، (۱۳۸۲) "روش‌های تجزیه خاک" چاپ اول، انتشارات ندای ضحی.
۶. خداوردی لوح، فتحی پ و همایی م، (۱۳۸۳)، "تخمین هوشمند منحنی رطوبتی خاک با استفاده از شبکه عصبی مصنوعی"، دومین کنفرانس ملی دانشجویی منابع آب و خاک، دانشگاه شیراز.
۷. خلیل مقدم ب و افیونی م، (۱۳۸۹) "کاربرد روش‌های رگرسیونی و شبکه‌های عصبی در تشکیل توابع انتقالی خاک به منظور تخمین هدایت هیدرولیکی اشباع خاک منطقه زاگرس مرکزی، اولین کنفرانس بین‌المللی مدلسازی گیاه، آب، خاک و هوا، دانشگاه شهید باهنر کرمان.
۸. خرسندی آ، همت ع، معصومی ا، و امیر فتاحی ر، (۱۳۸۵) "طراحی، ساخت و ارزیابی حسگر خازنی اندازه‌گیری رطوبت خاک به صورت بلادرنگ" پنجمین کنگره ملی مهندسی ماشین‌های کشاورزی و مکانیزاسیون، ص ۲۱۱-۲۱۹
۹. دوستی م، و بشارت س، (۱۳۸۲) "مدیریت آبیاری در گلخانه با استفاده از TDR جهت کاهش هزینه‌ها و افزایش راندمان آبیاری" پنجمین کنگره ملی مهندسی ماشین‌های کشاورزی و مکانیزاسیون، ص ۳۴۵-۳۵۰
۱۰. راکعی ب، (۱۳۸۲)، پایان‌نامه ارشد: "پهنه‌بندی خطر زمین‌لغزش با استفاده از سیستم شبکه عصبی در منطقه سفیددار گله استان سمنان"، دانشکده علوم، دانشگاه تربیت مدرس: پایان‌نامه ارشد.
۱۱. سرمیدیان ف، تقی زاده را. عسگری ح م و اکبرزاده ع، (۱۳۸۸)، "مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی برخی خصوصیات خاک مطالعه موردی استان گلستان"، مجله تحقیقات آب و خاک ایران، (۴۱)، ص ۲۲۰-۲۱۱.

۱۲. سلطانی محمدی ا، (۱۳۸۴)، پایان نامه ارشد: "تاثیر بافت خاک روی کالیبراسون TDR برای اندازه گیری رطوبت در شرایط خاک های خوزستان" دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز.
۱۳. شیرانی ح، صیاد غ، رفیعی نژاد ن، رضایی ارشد، (۱۳۸۹) "تعیین توابع انتقالی برای FC و PWP برخی خاک های استان کرمان با استفاده از رگرسیون آماری ومدل شبکه عصبی" سومین همایش ملی مدیریت شبکه های آبیاری وزهکشی. دانشگاه شهید چمران اهواز دانشکده مهندسی علوم آب.
۱۴. صفاری م، یثربی ج، معاذالهی م، فتحی ح و عمادی م، (۱۳۸۸)، "ارزیابی و مقایسه روش های میان یابی کریجینگ و شبکه عصبی مصنوعی برای پیش بینی تغییرات مکانی بعضی از خصوصیات شیمیایی خاک"، یازدهمین کنگره علوم خاک ایران (مدیریت خاک و امنیت غذایی)، دانشگاه علوم کشاورزی و منابع طبیعی گرگان.
۱۵. علیزاده ا، (۱۳۸۰) "رابطه آب و خاک و گیاه" چاپ دوم، انتشارات آستان قدس رضوی، دانشگاه امام رضا (ع).
۱۶. کشکولی ح.ع، و ظهرابی ن، (۱۳۸۴) "تعیین آزمایشگاهی خصوصیات هیدرولیکی خاک های ماسه ای در تعادل با سطح ایستابی با استفاده از TDR" ص ۱۶۳-۱۶۱ مجموعه مقالات فیزیک و روابط خاک، آب و گیاه.
۱۷. کیا م، (۱۳۸۹) "شبکه های عصبی در MALAB"، انتشارات کیان رایانه سبز. (۲۳۲ ص)، تهران.
۱۸. گیوی ج و پراشر ش، (۱۳۸۴)، "مقایسه مدل های رگرسیون چند متغیره تطبیقی و شبکه های عصبی مصنوعی در پیش بینی آب قابل جذب گیاه"، نهمین کنگره علوم خاک ایران.
۱۹. منهای م. و سیفی پور ن، (۱۳۷۷) "کاربرد هوش محاسباتی در کنترل" جلد دوم، انتشارات دانشگاه امیرکبیر تهران، ص ۲۳۶.
۲۰. منهای م، (۱۳۸۱) "مبانی شبکه های عصبی" جلد اول، انتشارات دانشگاه امیرکبیر، تهران، ص ۵۰۲.
۲۱. مزیدی م، (۱۳۸۸)، پایان نامه ارشد: "تاثیر ماده آلی روی دقت مطالعه انعکاس سنجی حوزه زمانی برای اندازه گیری رطوبت" دانشکده کشاورزی، دانشگاه کردستان.
۲۲. موسوی زاده مجرد ر. ا و سیاسخواه ع، (۱۳۸۷)، "پیش بینی منحنی مشخصه آب خاک با استفاده از مدل شبکه عصبی مصنوعی"، دومین همایش ملی مدیریت شبکه های آبیاری و زهکشی، دانشگاه شهید چمران اهواز.

۲۳. مهربانیان م، تقی زاده مهرجردی ر ا، دهقانی ف و زمانیان ک، (۱۳۸۸)، "مدلسازی خصوصیات خاک با استفاده از شبکه عصبی مصنوعی، رگرسیون چند متغیره و توابع انتقالی"، یازدهمین کنگره علوم خاک ایران (مدیریت خاک و امنیت غذایی)، دانشگاه علوم کشاورزی و منابع طبیعی گرگان.

۲۴. 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**، جلد هفدهم شماره اول.

۲۵. نوابیان م، لیاقت ع م و همایی م، (۱۳۸۳)، برآورد سریع هدایت الکتریکی با استفاده از شبکه عصبی، کنفرانس بین المللی منابع آب و خاک، دانشگاه شیراز، ص ۲۱۱-۲۰۳

۲۶. نوابیان م، لیاقت ع م، همایی م، (۱۳۸۳)، "تخمین هدایت آبی اشباع با استفاده از توابع انتقالی"، سومین کارگاه فنی زهکشی و محیط زیست، دانشگاه تهران.

۲۷. نجفی نیسانی ن، (۱۳۸۵)، پایان نامه ارشد: "برآورد بار رسوب رودخانه زاینده رود با استفاده از شبکه عصبی مصنوعی" دانشکده مهندسی زراعی، دانشگاه مازندران.

۲۸. نامدار خجسته د، شرفاء م، اسکندری ذ ا و عبداللهی آریپناهی ع، (۱۳۸۸)، "اندازه گیری EC محلول خاک به وسیله TDR با استفاده از شبکه های عصبی مصنوعی"، یازدهمین کنگره علوم خاک ایران (مدیریت خاک و امنیت غذایی)، دانشگاه علوم کشاورزی و منابع طبیعی گرگان.

۲۹. نامدار خجسته د، شرفاء م. و امید م، (۱۳۹۰) "برآورد رطوبت حجمی خاک با استفاده از شبکه عصبی مصنوعی" **مجله علوم و مهندسی آبخیزداری ایران**، شماره ۱۴، ص ۵۳ الی ۶۱.

۳۰. نژادرکابی م، رضانی مقدم م و طهماسبی نژاده، (۱۳۸۸)، "ارزیابی مقایسه ای مدل های ANFIS، RBF، MLP"، روابط تجربی و روش آماری رگرسیونی در برآورد میزان TDS آب"، دومین کنفرانس سراسری آب، دانشگاه آزاد اسلامی واحد بهبهان.

۳۱. Amini M. Abbaspour K. C. Khademi H. Fathipour N. Afyuni M. and Schulin R. (۲۰۰۵) "Neural network models to predict cation exchange capacity in arid regions of Iran" **European Journal of Soil Science**, August ۵۶: ۵۵۱-۵۵۹.

۳۲. Anon. (۱۹۸۰), “**Handbook of physics and Chemistry**”, ۶th end. CRC Press, Boca Rotan, FL., PP. E۵۸-E۳۶۱.
۳۳. Anderson J. A. (۱۹۹۵) “**Introduction to Neural Networks**” (Cambridge, MA:MIT Press).
۳۴. Barlow H. B. (۱۹۸۹) “**Unsupervised learning**” Neural Computation, vol. ۱, pp. ۲۹۵-۳۱۱.
۳۵. Bell M. A. and Van keulen H. (۱۹۹۵) “Soil pedotransfer function for four Mexican soils” **J.Soil. Sci. Soc. Am**, ۵۹, ۸۶۵-۸۷۱.
۳۶. Demuth H. and Beale B. (۱۹۹۴) “Neural Network Toolbox (User's Guide) for use with MATLAB”.
۳۷. Doaei M. Shabanpour-e-Shahrestani M. and Bagheri F. (۲۰۰۵). “Modelling of Saturated Hydraulic conductivity of Gilan Province involving Artificial Neural Networks”, **The Agricultural Science Research Report**, Faculty of Agriculture, Gilan University.
۳۸. Fatemi Aghda S. Sarikhani R. Teshnelab M. (۲۰۰۲) “Application of Artificial Neural Network to Predict Landslid- A case study from Talesh-Gilan, North of Iran”, Proceeding of ۹th congress of the International Association for Engineering Geology and the Environment, Durban.
۳۹. Gee G. and Bauder J. W. (۱۹۸۶) “Particle size distribution analysis. In: Klute, A. (Ed.), Method of soil analysis” Part ۱, second ed. Agron. Monogr. ۹. ASA and SSSA, Madison, WI, pp. ۳۸۳-۴۱۱.
۴۰. Givi J., Prasher S. O. and Patel R.M.(۲۰۰۴) “ Evaluation of pedotransfer function in predicting the soil water content at field capacity and wilting point” Agri Water Manage, ۷۰, ۸۳-۹۶.
۴۱. Haykin, S. (۱۹۹۹). Neural networks " **A comprehensive foundation** ". Prentice Hall , NJ

ξϣ. Herkelrath W.N., Hamburg S.P. and Murphy F.(1991) “Automatic, real-time monitoring of soil moisture in a remote field area with time domain reflectometry” **Water. Rose. Rese. J.**, 27:807-814.

ξϣ. Heuser S.A., Brandt C.C. and Jardin P.M. (2000) “Using soil physical and chemical properties to estimate bulk density” **J. Soil Sci. Am**, 64,51-56.

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

ξο. Jacobsen O.H. and Schjonning P. (1993) “ A laboratory calibration of time domain reflectometry for soil water measurement including effects of bulk density and texture” **Hydro. J.**, 101: 147-157.

ξϛ. Kalkan E., Akbulut S. and Torttum A. (2008) “Prediction of the unconfined compressive strength of compacted granular soils by using inference systems” **Environ Geol**, 5,324-330.

ξϣ. Kasheipour S.M., Lin B. and Flaconer F.A. (2000) “Neural networks for predicting seawater bacterial levels” **Proceedings of the Institution of Civil Engineers. Water Management**. 108:111-118

ξΛ. Kaur R., Kumar S. and Gurung H. P. (2002) “ A pedotransfer function soil data and its comparison with existing PTFs” **Aust. J. Soil Res**, 40,847-857.

ξϣ. Krogh L., Breuning-madsen H. and Greve M.H. (2000) “Cation exchange capacity pedotransfer function for Danish soils” **Soil and Plant Sci**, 50,1-12.

οο. Licznar P. and Nearing M. A. (2003). “Artificial neural networks of soil erosion and runoff prediction at the plot scale” **Catena** 51: 89- 114.

ο1. Malicki M. A. Plagge R. and Roth C.H. (1994) “ Influence of matrix on TDR soil moisture reading and its elimination Proc of the Symp on time domain reflectometry in environmental Infra-structure, and Minig Applications” **Evaston, IL., Bure of Mines.**, 19:100-114.

୧୪. Marcel G.S., Feike J.L., and Martinus T., van Genuchten h. (୧୯୯୮). “Neural Network Analysis for Hierarchical Prediction of Soil Hydraulic Properties”, Soil Science Society.
୧୫. Maroufpoor E. Emamgholizadeh S. Torabi H. and Behzadinasab M. (୨୦୦୯) “Impact of soil texture on the calibration of TDR for water content measurement” **App. Sci. J.**
୧୬. Merdun, H., Cinar, O., Meral, R., and Apan, M. (୨୦୦୬). “Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity” **Soil and Tillage**
୧୭. Minsany B. and Mcbratney A.B. (୨୦୦୨) “The Neuro-m method for fitting neural network parametric pedotransfer function” . **Soil Sci. Soc. Am.J.**, ୬୬:୩୦୨-୩୧୧
୧୮. Navvabian M. Liaghat E.M. and Homaei M. (୨୦୦୫). “Rapid Estimation of Hydraulic Conductivity using Neural Networks”. In: Proceedings of the second National Student Conference on Water and Soil Resources. Shiraz Uni. Press.
୧୯. Pachepsky Ya. A., D. Timlin, and G. Varallyay.(୧୯୯୬). “Artificial neural networks to estimate soil water retention from easily measurable data”. **Soil Sci. Soc. Am. J.** ୬୦: ୪୨୪-୪୩୩.
୨୦. Parasuraman K., Elshorbagy C. and Si B. (୨୦୦୬) “Estimating saturated hydraulic conductivity in spatially variable field using neural network in Ensembles” **J. Soil Sci. Soc. Am.**, ୭୦, ୧୮୦୧-୧୮୦୯.
୨୧. Persson M. and Berndtsson R. (୧୯୯୮) “Texture and electrical conductivity effects on temperature dependency in time domain reflectometry” **Soil. Sci. Soc. Ame. J.**, ୬୨:୮୮୪-୮୯୩.
୨୨. Ping Zou , Jingsong Yang , Jianrong Fu , Guangming Liu , Dongshun Li . (୨୦୦୦) “Artificial neural network and time series models for predicting soil salt and water content Institute of Soil Science”, Chinese Academy of Sciences, ୨୧୦୦୦୮ Nanjing, China Institute of Environment, Resource, Soil and Fertilizer, Zhejiang Academy of Agricultural Sciences.

٦١. Regalado C.M., Carpena R.M., Socorro A.R. and Moreno L.M. (٢٠٠٣) “Time domain reflectometry models as a tool to understand the dielectric response of volcanic soils” **Elsevier Science.**, ١١٧: ٣١٣-٣٣٠.
٦٢. Roth C. H., Malicki M.A. and Plagge R. (١٩٩٢) “ Empirical evaluation of the relationship between soil dielectric constant and volumetric water as the basis for calibration soil moisture measurements by TDR” **Soil. Sci. J.**, ٤٣:١-١٣.
٦٣. Rub G., Kruse R., Schneider M. and Wagner P. (٢٠٠٩). “Using advanced regression models for determining optimal soil heterogeneity indicators”. *Studies in Classification, Data Analysis, and Knowledge Organization*, pages ٤٦٣-٤٧١.
٦٤. Saffari M., Yasrebi J., Sarikhani F., Gazni R., Moazallahi M., Fathi H and Emadi M, (٢٠٠٩). “Evaluation of Artificial Neural Network Models for Prediction of Spatial Variability of Some Soil Chemical Properties” **Research Journal of Biological Sciences.** ٤:(٧) ٨١٥-٨٢٠.
٦٥. Sarangi A. and Bhattacharya A.K. (٢٠٠٥) “Comparison of Artificial Neural Network and regression models for sediment loss prediction from Banha watershed in India. Water Technology Center. IARI. Pusa Campus. New Dehli ١١٠٠١٢. India.
٦٦. Sarmadian F. and Keshavarzi A. (٢٠١٠) “Developing Pedotransfer Functions for Estimating Some Soil Properties using Artificial Neural Network and Multivariate Regression Approaches” **International Journal of Environmental and Earth Sciences** ١:١ ٢٠١٠.
٦٧. Sarmadian F. and Taghizadeh Mehrjardi R. (٢٠٠٨) “Modeling of Some Soil Properties Using Artificial Neural Network and Multivariate Regression in Gorgan Province, North of Iran” **Global Journal of Environmental Research** ٢ (١): ٣٠-٣٥.
٦٨. Schaap M. G. and Leij F. J. (٢٠٠٠) “Improved prediction of unsaturated hydraulic conductivity with the Mualem-Van Genuchten model” **J. Soil Sci. Am.**, ٦٤, ٨٤٣-٨٥١.
٦٩. Schaap M. G., Leij F. J. and van Genuchten M. Th. (١٩٩٨) “ Neural network analysis for hierarchical prediction of soil hydraulic properties” **J. Soil Sci. Soc . Am.**, ٦٢, ٨٤٧-٨٥٥.
٧٠. Schaap M.G. and Leij F.J. (١٩٩٨) “Using neural networks to predict soil water retention and soil hydraulic conductivity” **Soil and Tillage Research**, ٤٧:٣٧-٤٢.

٧١. Shahin M.A., Jaksa M.B. and Maier H.R. (٢٠٠١) “Artificial neural network applications in geotechnical engineering. *Australian Geomechanics*. ٤٩-٦٢.
٧٢. Sparks D. L., Page A. L., Helmke P A., Leoppert R. H., Soltanpour P. N., Tabatabai M A., Johnston G. T. and Summer M. E., (١٩٩٦) “**Methods of soil analysis**”, SSSA, Madison, Wisconsin.
٧٣. Stafford J.V. (١٩٨٨) “Remote non-contact and in-situ measurement of soil moisture content” a review. **J. agric. Eng. Res.J.**, ٤٢: ١٥١-١٧٢
٧٤. Tareghian R. and Kashefipour S.M. (٢٠٠٧) “Application of fuzzy systems and artificial neural networks for flood forecasting. **Journal of Applied Sciences**. ٧(٢٢): ٣٤٥١-٣٤٥٩
٧٥. Tamari S., Wosten J. H. M. and Ruz-suarez J. C. (١٩٩٦) “Testing an artificial neural network for predicting soil hydraulic conductivity” **J. Soil Sci. Soc. Am**, ٤٩,١١٠٠-١١٠٥.
٧٦. Topp G.C., Zeglin S.G., and White I. (١٩٩٤) “Monitoring soil water content using TDR: an overview of progress. Symposium and workshop on time-domain reflectometry in Environmental, Infrastructure, and mining applications”. **Bureau of Mines, PP ٥٦-٦٥**.
٧٧. Vos B.D., Meirvenne M.V., Quataert P., Deckers J. and Muys B. (٢٠٠٥) “Predictive quality of pedotransfer function for estimating bulk density of forest soil” **J. Soil Sci. Am**, ٦٩,٥٠٠-٥١٠.
٧٨. Widrow B. Leher M. (١٩٩٠) “**٣٠ Years of adaptive Neural Networks; Perceptron, Madaline and Backpropagation**” Proceeding IEEE.
٧٩. Yilmaz I. and Kaynar O. (٢٠١١) “Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils” *Expert Systems with Applications* ٣٨: ٥٩٥٨-٥٩٦٦.

پیوست ۱- نتایج حاصل از اجرای مدل MLP شبکه عصبی با تعداد لایه های پنهان مختلف و توابع مختلف در تخمین رطوبت حجمی خاک در سه نوع بافت سبک، متوسط و سنگین

MAE	RMSE	R ²	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۱/۱۹۱	۱/۵۱۴	۰/۹۴	آموزش	۱	سیگموئید Sigmoid	سبک
۱/۵۳۲	۱/۸۰۹	۰/۸۹	صحت یابی			
۱/۱۹۲	۱/۵۲۶	۰/۹۴	آموزش	۲		
۱/۵۱۶	۱/۷۹۴	۰/۸۹	صحت یابی			
۱/۳۷۶	۱/۷۳۹	۰/۹۲	آموزش	۳		
۱/۶۷۳	۲/۰۱۵	۰/۸۶	صحت یابی			
۱/۸۹۶	۲/۲۵۴	۰/۹۰	آموزش	۴		
۲/۱۲۵	۲/۵۶۹	۰/۸۷	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۲/۷۵	۳/۱	۰/۷۵	آموزش	۱	گوسن Gaussian	سبک
۲/۳	۲/۶	۰/۶۹	صحت یابی			
۰/۷۰۹	۰/۸۸۷	۰/۹۹	آموزش	۲		
۱/۱۴۰	۱/۳۲۱	۰/۹۷	صحت یابی			
۰/۶۰۵	۰/۷۷۲	۰/۹۹	آموزش	۳		
۰/۷۹۳	۰/۹۳۱	۰/۹۸	صحت یابی			
۰/۹۱۹	۱/۱۲۳	۰/۹۸	آموزش	۴		
۱/۱۴۰	۱/۳۳۴	۰/۹۷	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۱/۴۲۵	۱/۶۱۲	۰/۹۴	آموزش	۱	تانژانت هیپربولیک Tangent Hyperbolic	سبک
۰/۹۷۷	۱/۲۶۳	۰/۹۵	صحت یابی			
۱/۳۱۶	۱/۵۰۷	۰/۹۲	آموزش	۲		
۰/۹۰۷	۱/۱۲۶	۰/۹۷	صحت یابی			
۱/۰۱۶	۱/۳۲۰	۰/۹۶	آموزش	۳		
۱/۳۴۵	۱/۵۷۹	۰/۹۲	صحت یابی			
۱/۷۴۱	۲/۵۶۱	۰/۷۰	آموزش	۴		
۲/۲۳۵	۲/۸۶۱	۰/۶۸	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۷۲۷	۰/۹۴۰	۰/۹۸	آموزش	۱	سکانت هیپربولیک Secant Hyperbolic	سبک
۱/۰۹۴	۱/۲۷۹	۰/۹۵	صحت یابی			
۰/۶۳۲	۰/۸۰۴	۰/۹۸	آموزش	۲		
۰/۶۸۵	۰/۸۶۰	۰/۹۷	صحت یابی			
۰/۸۰۰	۰/۹۹۵	۰/۹۸	آموزش	۳		
۱/۲۰۵	۱/۴۰۲	۰/۹۳	صحت یابی			
۱/۵۶۲	۲/۰۴۶	۰/۸۹	آموزش	۴		
۱/۸۷۱	۲/۲۲۶	۰/۸۳	صحت یابی			

MAE	RMSE	R ^۲	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۸۷۰	۱/۱۱۶	۰/۹۵	آموزش	۱	سیگموید Sigmoid	متوسط
۱/۰۴۶	۱/۲۸۳	۰/۹۲	صحت یابی			
۰/۸۸۵	۱/۱۳۷	۰/۹۵	آموزش	۲		
۱/۰۵۵	۱/۲۷۱	۰/۹۲	صحت یابی			
۰/۷۰۹	۱/۰۹۹	۰/۹۴	آموزش	۳		
۱/۰۳۳	۱/۲۶۷	۰/۹۲	صحت یابی			
۲/۱۲۵	۲/۷۴۱	۰/۸۵	آموزش	۴		
۲/۲۵۶	۲/۶۸۵	۰/۸۰	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۱/۸۵۶	۲/۹۵۱	۰/۸۵	آموزش	۱	گوسن Gaussian	متوسط
۱/۹۶۲	۲/۹۸۷	۰/۸۰	صحت یابی			
۰/۵۷۸	۰/۷۸۲	۰/۹۷	آموزش	۲		
۰/۶۴۴	۰/۸۴۶	۰/۹۶	صحت یابی			
۱/۲۴۹	۱/۴۶۴	۰/۹۷	آموزش	۳		
۱/۳۵۱	۱/۵۷۰	۰/۹۸	صحت یابی			
۱/۳۴۱	۱/۶۹۱	۰/۸۸	آموزش	۴		
۱/۴۹۷	۲/۰۰۳	۰/۹۲	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۵۰۵	۰/۶۸۳	۰/۹۷	آموزش	۱	تانژانت هیپربولیک Tangent Hyperbolic	متوسط
۰/۴۳۵	۰/۵۳۴	۰/۹۸	صحت یابی			
۰/۵۵۵	۰/۷۵۰	۰/۹۷	آموزش	۲		
۰/۵۹۶	۰/۸۲۰	۰/۹۶	صحت یابی			
۰/۶۸۲	۰/۸۶۸	۰/۹۸	آموزش	۳		
۰/۶۰۵	۰/۷۹۰	۰/۹۸	صحت یابی			
۱/۷۵۲	۲/۵۳۲	۰/۷۵	آموزش	۴		
۲/۱۵۳	۲/۸۵۳	۰/۷۲	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۴۸۷	۰/۶۶۰	۰/۹۸	آموزش	۱	سکانت هیپربولیک Secant Hyperbolic	متوسط
۰/۵۳۴	۰/۶۷۹	۰/۹۹	صحت یابی			
۰/۴۴۸	۰/۶۲۰	۰/۹۷	آموزش	۲		
۰/۳۱۲	۰/۴۰۱	۰/۹۹	صحت یابی			
۰/۸۴۱	۱/۰۷۶	۰/۹۵	آموزش	۳		
۱/۰۱۹	۱/۲۲۵	۰/۹۳	صحت یابی			
۲/۱۴۵	۲/۹۶۳	۰/۶۷	آموزش	۴		
۲/۹۸۳	۳/۰۲۵	۰/۶۳	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۵۴۴	۰/۷۶۲	۰/۹۷	آموزش	۱	سیگموئید Sigmoid	سنگین
۰/۵۹۹	۰/۸۵۱	۰/۹۶	صحت یابی			
۰/۶۱۳	۰/۸۵۶	۰/۹۷	آموزش	۲		
۰/۶۰۷	۰/۸۷۲	۰/۹۶	صحت یابی			
۰/۵۸۰	۰/۸۰۲	۰/۹۸	آموزش	۳		
۰/۵۵۱	۰/۷۸۵	۰/۹۷	صحت یابی			
۲/۱۲۸	۲/۶۵۳	۰/۷۵	آموزش	۴		
۲/۵۶۳	۲/۷۵۳	۰/۷۰	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۱/۲۳۶	۱/۹۶۲	۰/۸۲	آموزش	۱	گوسن Gaussian	سنگین
۱/۸۵۳	۲/۱۵۴	۰/۷۵	صحت یابی			
۰/۴۷۲	۰/۶۶۹	۰/۹۸	آموزش	۲		
۰/۶۲۲	۰/۸۶۶	۰/۹۶	صحت یابی			
۰/۴۷۱	۰/۶۹۱	۰/۹۸	آموزش	۳		
۰/۶۷۶	۰/۹۳۱	۰/۹۶	صحت یابی			
۰/۴۸۹	۰/۶۷۰	۰/۹۸	آموزش	۴		
۰/۷۱۶	۱	۰/۹۷	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۴۸۰	۰/۶۶۷	۰/۹۸	آموزش	۱	تانژانت هیپربولیک Tangent Hyperbolic	سنگین
۰/۶۰۱	۰/۸۴۵	۰/۹۷	صحت یابی			
۰/۴۶۶	۰/۶۵۷	۰/۹۹	آموزش	۲		
۰/۶۴۲	۰/۹۰۳	۰/۹۸	صحت یابی			
۰/۵۴۸	۰/۷۹۴	۰/۹۸	آموزش	۳		
۰/۷۴۲	۰/۸۹۸	۰/۹۶	صحت یابی			
۰/۴۸۷	۰/۶۷۴	۰/۹۸	آموزش	۴		
۰/۶۰۶	۰/۸۵۲	۰/۹۶	صحت یابی			

MAE	RMSE	R^2	مرحله محاسباتی	تعداد لایه های پنهان	تابع محرک	بافت
۰/۴۶۵	۰/۶۷۰	۰/۹۸	آموزش	۱	سکانت هیپربولیک Secant Hyperbolic	سنگین
۰/۶۳۴	۰/۸۷۱	۰/۹۷	صحت یابی			
۰/۴۶۸	۰/۶۷۷	۰/۹۹	آموزش	۲		
۰/۶۵۵	۰/۸۸۴	۰/۹۹	صحت یابی			
۰/۴۸۰	۰/۶۹۱	۰/۹۸	آموزش	۳		
۰/۶۵۳	۰/۹۲۶	۰/۹۶	صحت یابی			
۰/۴۸۴	۰/۶۹۷	۰/۹۸	آموزش	۴		
۰/۶۲۶	۰/۸۸۶	۰/۹۷	صحت یابی			

Abstract

Most measurable important factors in water and soil conservation and hydrology are soil volumetric moisture and plants water available. Thus measuring these parameters is very essential. Regard to the difficulties of direct measurement of soil volumetric moisture, using indirect methods for estimation of this parameter, has received attention in recent years. In this study use soil parameters such as bulk density, porosity, organic matter and day in three soil texture (clay, silt and sand) to estimate soil volumetric moisture with artificial neural network and its result compared with nonlinear regression model and TDR method. moreover time variation of volumetric moisture in soil textures had survived. In order to evaluate the performance of these models, the statistical parameters such as root mean square error (RMSE), mean absolute error (MAE) and correlation coefficient (R^2) were used. The result show artificial neural network with R^2 (0.97, 0.99, 0.97), RMSE (0.860, 0.401, 0.780) and MAE (0.680, 0.312, 0.501) for test stage of sand, silt and clay texture in estimating soil moisture volumetric was better than nonlinear regression model and TDR method, respectively.

Keywords: Artificial neural network, nonlinear regression model, soil moisture volumetric, Time variation.



Shahrood University of Technology
Faculty of Agriculture
Soil and Water Department
M.S.c. Thesis

The Estimation of Soil Moisture Using Artificial Neural Network

Meisam Abolkherian

Supervisors:

Dr H. Ghorbani

Dr S. Emamgholizadeh

Advisors:

Dr E. Maroufpoor

Dr kh. Azhdari

Date:

July ۲۰۱۳