


بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشگاه صنعتی شاهرود

دانشکده کشاورزی

پایان نامه کارشناسی ارشد شیمی و حاصلخیزی خاک

پیش بینی عناصر آهن و روی خاک در اراضی شهرستان های دهدشت و چرام با استفاده از  
مدل های شبکه ی عصبی مصنوعی (ANN) و انطباق عصبی-فازی (ANFIS)

نگارنده: زهره پاداش

استاد راهنما

دکترهادی قربانی

دکترشاهین شاهسونی

استاد مشاور

دکتر وجیهه درستکار

تیر ۱۳۹۷



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

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای زهره پاداش با شماره دانشجویی ۹۴۳۷۴۰۴ رشته کشاورزی گرایش علوم خاک تحت عنوان پیش بینی عناصر آهن و روی خاک در اراضی شهرستان های دهدشت و چرام با استفاده از مدل های شبکه ی عصبی مصنوعی (ANN) و انطباق عصبی - فازی (ANFIS) که در تاریخ ۱۳۹۷/۰۴/۰۵ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می گردد:

قبول (با درجه: ...):  مردود

نوع تحقیق: نظری  عملی

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	هادی قربانی	دانشیار	
۲- استاد راهنمای دوم	شاهین شاهسونی	استادیار	
۳- استاد مشاور	وجیهه درستکار	استادیار	
۴- نماینده تحصیلات تکمیلی	زهره گنجی نوروزی	استادیار	
۵- استاد ممتحن اول	علی عباسپور	دانشیار	
۶- استاد ممتحن دوم	صمد امامقلی زاده	دانشیار	

نام و نام خانوادگی رئیس دانشکده: محمد رضا عامریان



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

این پژوهش پیشگامی است به خانواده عزیز و فداکارم، که

عاشقانه و صبورانه، همیار و همراه زندگی ام هستند

و

تمامی کسانی که بخند زندگی را بر وجودم نشانند.

## تشکر و قدردانی:

بر خود لازم می‌دانم از زحمات جناب آقای هادی قربانی و شاپین شاهسونی به  
عموان استاد راهنما و سرکار خانم وحیده دستکار به عموان استاد مشاور که در این تحقیق  
مرا صمیمانه یاری نموده و در مسیر به سرانجام رساندن این پروژه نقش قابل توجهی را  
ایفا کردند تشکر نمایم.

## تعهد نامه

اینجانب زهره پاداش دانشجوی دوره کارشناسی ارشد رشته علوم خاک دانشکده کشاورزی دانشگاه صنعتی شاهرود نویسنده پایان نامه پیش بینی عناصر آهن و روی خاک در اراضی شهرستان های دهدشت و چرام با استفاده از مدل های شبکه ی عصبی مصنوعی (ANN) و انطباق عصبی-فازی (ANFIS) تحت راهنمایی دکتر هادی قربانی و دکتر شاهین شاهسونی 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.

## چکیده

در این پژوهش با استفاده از شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی - فازی تطبیقی (ANFIS) به پیش‌بینی برخی عناصر میکرو خاک پرداخته شده است. مطالعه مورد نظر در شهرستان چرام و دهدشت با یرداشت ۹۰ نمونه خاک سطحی انجام شد. بدین منظور از پارامترهای زود یافت خاک مانند آهک خاک، pH، EC و ماده آلی، آهن و روی خاک به عنوان ورودی به مدل استفاده شد. نتایج بدست آمده نشان داد که همبستگی بین عناصر آهن و روی با پارامترهای ورودی نشان داد که بیشترین میزان همبستگی را ماده آلی و درصد رس با عنصر آهن و اسیدیت و هدایت الکتریکی با عنصر روی خاک دارد. نتایج شبکه پرسپترون (MLP) برای محاسبه عناصر آهن و روی نشان داد که بهترین ضریب تبیین نسبت به سایر توابع مربوط به تابع گوسین که ۰/۹۳ برای تانژانت سیگموئید و ۰/۹۱ برای لگاریتم سیگموئید و همچنین ۰/۳۱ برای تانژانت سیگموئید و ۰/۳ برای لگاریتم سیگموئید به ترتیب برای عنصر آهن و روی می‌باشد. نتایج حاصل اجرای مدل سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی خاک نشان داد که مدل ANFIS با تابع عضویت گوسین برای هر دو عنصر آهن و روی و با داشتن ضریب تبیین ۰/۹۹ برای آهن و همچنین ضریب تبیین ۰/۷۸ برای عنصر روی بهترین حالت را نسبت به دیگر توابع دارد. نتایج حاصل از مقایسه دو مدل مورد استفاده شده نشان می‌دهد مدل ANFIS با داشتن ضریب تبیین ۰/۹۹، ۰/۷۸ به ترتیب برای عناصر آهن و روی خاک نسبت به مدل شبکه عصبی مصنوعی با داشتن ضریب تبیین ۰/۹۳ و ۰/۹۱ و همچنین ۰/۳۱ و ۰/۳۰ به ترتیب برای عناصر آهن و روی خاک و در مراحل آموزش و صحت‌سنجی بهترین کارایی را دارد. ضریب تبیین مدل ANFIS نسبت به شبکه عصبی بیشتر و میزان خطای آزمون، خطای آزمایش و خطای شبیه‌سازی برای عناصر آهن و روی در شبکه عصبی بالاتر است که نشان‌دهنده کارایی پایین‌تر مدل شبکه عصبی مصنوعی نسبت به مدل ANFIS دارد.

## واژه‌های کلیدی

شبکه هوش مصنوعی ، سیستم استنتاج فازی، آهن، روی،

## فهرست

### فصل اول: مقدمه

صفحه

- ۱-۱- مقدمه..... ۲
- ۲-۱- ضرورت تحقیق..... ۵
- ۳-۱- روش انجام کار..... ۶
- ۴-۱- اهداف..... ۷

### فصل دوم: کلیات و مرور منابع

- ۱-۲- تعریف خاک..... ۱۰
- ۲-۲- بررسی عناصر غذایی دیربافت اندازه‌گیری شده..... ۱۱
- ۱-۲-۲- آهن..... ۱۱
- ۲-۲-۲- روی..... ۱۲
- ۳-۲- تعامل عنصر روی و آهن..... ۱۳
- ۴-۲- اهمیت عناصر غذایی مذکور و روابط آن‌ها با ویژگی‌های خاک..... ۱۴
- ۵-۲- شبکه عصبی مصنوعی (ANN)..... ۱۵
- ۱-۵-۲- توانایی‌های شبکه عصبی..... ۱۷
- ۱-۵-۲- یادگیری تطبیقی..... ۱۷
- ۲-۱-۵-۲- خود سازماندهی..... ۱۸
- ۳-۱-۵-۲- عملکردهای بلادرنگ..... ۱۸
- ۴-۱-۵-۲- تحمل خطا..... ۱۸
- ۵-۱-۵-۲- دسته بندی..... ۱۹
- ۶-۱-۵-۲- تعمیم دهی..... ۱۹
- ۷-۱-۵-۲- پایداری - انعطاف پذیری..... ۱۹
- ۲-۵-۲- آموزش شبکه‌های عصبی..... ۱۹
- ۱-۲-۵-۲- آموزش با ناظر..... ۱۹
- ۲-۲-۵-۲- آموزش بدون ناظر..... ۲۰
- ۳-۵-۲- انواع شبکه عصبی..... ۲۰
- ۶-۲- سیستم استنتاج تطبیقی عصبی-فازی (ANFIS)..... ۲۳

### فصل سوم: مواد و روش‌ها

- ۱-۳- موقعیت جغرافیایی منطقه..... ۳۰
- ۲-۳- وضع موجود کشاورزی و پوشش طبیعی..... ۳۰
- ۳-۳- شرایط توپوگرافی..... ۳۰
- ۴-۳- هواشناسی منطقه‌ای..... ۳۱
- ۵-۳- برداشت و آماده‌سازی نمونه‌های خاک..... ۳۱
- ۶-۳- تجزیه شیمیایی و فیزیکی خاک..... ۳۱
- ۱-۶-۳- عناصر آهن و روی موجود در خاک..... ۳۲
- ۷-۳- هوش مصنوعی..... ۳۲



- ۳-۸- شبکه عصبی مصنوعی..... ۳۲
- ۳-۹- ساختار سیستم استنتاج تطبیقی عصبی فازی (ANFIS)..... ۳۵
- ۳-۱۰- روش تحقیق..... ۳۳

#### فصل چهارم: نتایج و بحث

- ۴-۱- همبستگی بین پارامترهای اندازه‌گیری شده..... ۴۰
- ۴-۲- پارامترهای آماری ویژگی‌های مورد مطالعه..... ۴۲
- ۴-۳- اجرای شبکه عصبی پرسپترون (MLP) برای محاسبه عناصر آهن و روی..... ۴۷
- ۴-۴- اجرای مدل سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی خاک..... ۵۳
- ۴-۵- آنالیز حساسیت بر روی پارامترهای ورودی به مدل شبکه عصبی مصنوعی و ANFIS..... ۵۵
- ۴-۶- اجرای مدل سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی خاک..... ۵۹
- ۴-۷- مقایسه مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی فازی..... ۶۲

#### فصل پنجم نتیجه‌گیری و پیشنهادها

- ۵-۱- نتیجه‌گیری..... ۶۶
- ۵-۲- پیشنهادها..... ۶۶
- فهرست منابع (فارسی و لاتین)..... ۶۷

## فهرست جداول

جدول ۱-۴ - همبستگی میان پارامترهای زودیافت خاک با غلظت آهن و روی خاک قابل عصاره‌گیری با DTPA	خاک.....	۴۰
جدول ۲-۴ - پارامترهای آماری فاکتورهای مورد مطالعه.....	.....	۴۲
جدول ۳-۴ - نتایج حاصل از اجرای بهترین ساختار شبکه عصبی برای پیش‌بینی آهن خاک.....	.....	۴۸
جدول ۴-۴ - نتایج حاصل از اجرای بهترین ساختار شبکه عصبی برای پیش‌بینی روی خاک.....	.....	۵۰
جدول ۵-۴ - نتایج حاصل از اجرای بهترین ساختار شبکه ANFIS برای پیش‌بینی آهن خاک.....	.....	۵۴
جدول ۶-۴ - نتایج حاصل از اجرای بهترین ساختار شبکه ANFIS برای پیش‌بینی عصر آهن و روی خاک.....	.....	۵۹

## فهرست شکل‌ها

- شکل ۳-۱: موقعیت مورد مطالعه در شهرستان‌های چرام و دهدشت..... ۳۰
- شکل ۳-۲: مدل ریاضی یک نرون ..... ۳۳
- شکل ۳-۳ اجزای تشکیل دهنده یک پرسپترون چندلایه..... ۳۵
- شکل ۳-۴ ساختار مدل انفیس..... ۳۷
- شکل ۴-۱- نمودار مقدار خطا در مقابل تعداد نورون لایه میانی در پیش‌بینی عنصر آهن برای تابع محرک تانسیگ و لوگسیگ توسط مدل MLP ..... ۴۹
- شکل ۴-۲- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای غلظت روی خاک با تابع محرک تانسیگ مدل MLP..... ۵۰
- شکل ۴-۳- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای غلظت آهن خاک با تابع محرک لگسیگ مدل MLP..... ۵۰
- شکل ۴-۴- نمودار مقدار خطا در مقابل تعداد نورون در پیش‌بینی غلظت عنصر روی خاک با دو تابع محرک تانسیگ و لوگسیگ در لایه میانی توسط مدل MLP..... ۵۱
- شکل ۴-۵- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی عنصر روی برای تابع محرک تانسیگ مدل MLP..... ۵۲
- شکل ۴-۶- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی عنصر روی برای تابع محرک لگسیگ مدل MLP..... ۵۳
- شکل ۴-۷- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای عنصر آهن توسط مدل ANFIS..... ۵۵
- شکل ۴-۸- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای عنصر روی توسط مدل ANFIS..... ۵۶
- شکل ۴-۹- آنالیز حساسیت درصد خطا سهم پارامترهای ورودی در تخمین میزان عنصر آهن خاک مدل ANN ..... ۵۸
- شکل ۴-۱۰- آنالیز حساسیت درصد خطا سهم پارامترهای ورودی در تخمین میزان عنصر روی خاک مدل ANN..... ۵۸
- شکل ۴-۱۱- آنالیز حساسیت سهم پارامترهای ورودی در پیش‌بینی میزان عنصر آهن خاک مدل ANFIS ..... ۵۹
- شکل ۴-۱۲- آنالیز حساسیت سهم پارامترهای ورودی در پیش‌بینی میزان عنصر روی خاک مدل ANFIS ..... ۵۹
- شکل ۴-۱۳- نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای عنصر آهن توسط مدل ANFIS ..... ۶۱
- شکل ۴-۱۴: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای عنصر روی توسط مدل ANFIS ..... ۶۲



# فصل اول

## مقدمہ

انسان‌های اولیه تا زمانی که مواد غذایی خود را از طریق شکار به دست می‌آوردند توجهی چندان به خاک نداشتند. ولی به تدریج که کشت و دامپروری جایگزین شکار شده اهمیت خاک نیز افزایش یافته است. این تغییر در حدود ۹۰۰۰ سال پیش در کوه‌های زاگرس و حوالی خوزستان و قسمتی از عراق امروزی بین رودخانه‌های دجله و فرات صورت گرفته و در واقع اولین انقلاب کشاورزی از سرزمین ایران آغاز گردیده است. در سال‌های دور خاک به عنوان بخش مرده پوسته زمین به شمار می‌رفت. تا اینکه در سال ۱۸۸۰ میلادی توسط دانشمندی روسی به نام داکوچائف به عنوان بخشی زنده و دارای ارزش مورد مطالعاتی قرار گرفت. خاک به عنوان منبع تولید مواد غذایی از اهمیت بسزای در شکوفایی تمدن‌ها مؤثر بوده، به طوری که برخی ملل بر اثر از بین رفتن قدرت زایش خاک تحلیل رفته و رشد و توسعه آن‌ها مختل شده است (محرم نژاد و تهرانی، ۱۳۸۹).

علی‌رغم تعاریف متعدد به عمل آمده از این عنصر محیط زیستی، در این قسمت به ارائه دو تعریف از خاک که مورد پذیرش جهانی نیز هست، اکتفا می‌شود. در اولین تعریف، خاک به عنوان سیستمی طبیعی و پویا در سطح زمین و متشکل از مواد آلی و معدنی شناخته می‌شود. این سیستم در اثر فرآیندهای فیزیکی، شیمیایی و زیستی از جمله هوازدگی سنگ‌ها و پوسیدگی پوشش گیاهی تکوین یافته است. مواد خاک شامل مواد آلی، رس، سیلت، شن و سنگ‌ریزه به گونه‌ای مخلوط شده‌اند که محیط رشدی را برای گیاهان خشکی فراهم می‌نماید. خاک، پروفایل منظمی از لایه‌های کم و بیش موازی با سطح زمین دارد که در اثر تعامل مواد مادری، اقلیم، موجودات زنده و توپوگرافی در طول یک دوره زمانی طولانی شکل گرفته است. تفاوت خاک و مواد مادری ناشی از مورفولوژی، خواص و ویژگی‌های آن می‌باشد (هاتون و چارمن، ۱۹۸۶). شورای اروپا نیز تعریفی مشابه با اندکی تغییر از خاک ارائه می‌کند: خاک بخش جدایی‌ناپذیر زیست بوم‌های کره زمین می‌باشد که در حد فاصله بین سطح زمین و سنگ مادر واقع شده است. خاک به چندین لایه افقی متوالی با ویژگی‌های فیزیکی، شیمیایی، و زیستی خاص طبقه‌بندی می‌شود. از نقطه نظر تاریخی استفاده از خاک و از

نقطه نظر محیط‌زیست و اکولوژی، مفهوم خاک دربرگیرنده سنگ‌های رسوبی منفذدار و مواد نفوذپذیر دیگر و آب همراه آن‌ها و منابع آب زیرزمینی می‌باشد (هانام و بوئر، ۲۰۰۲).

خاک یکی از مهم‌ترین اجزا اکوسیستم بوده که محیطی مناسب برای ذخیره عناصر غذایی و انجام فرایندها و فعالیت‌های بیولوژیکی، فیزیکی و شیمیایی محسوب می‌گردد. ارتباط تنگاتنگ کیفیت و سلامت خاک با فراهم آوردن شرایط نیل به اهداف کشاورزی پایدار و مهم‌تر اینکه تضمین سلامت عمومی از طریق ارتقای کیفیت محصولات غذایی و در نهایت امنیت غذایی می‌باشد. مدیریت صحیح خاک در راستای ارتقای سلامت و کیفیت آن تأمین کننده‌ی امنیت غذایی و تسریع کننده‌ی دستیابی به اهداف کشاورزی پایدار می‌باشد. خاک هر منطقه به نوعی سرمایه ملی آن منطقه محسوب می‌شود زیرا امنیت غذایی هر کشور نماد استقلال آن کشور است و تخریب خاک باعث از بین رفتن کشاورزی پایدار و به تبع آن از بین رفتن امنیت غذایی و در نهایت منجر به زوال تدریجی استقلال آن کشور می‌گردد (هاتف فرد و همکاران، ۱۳۹۴).

نظام‌های کشاورزی رایج برای حفظ و تقویت باروری خاک به طور گسترده به کودهای شیمیایی روندی نامعقول داشته و در حال حاضر سالانه ۱۳۵ میلیون تن کود شیمیایی در بخش کشاورزی مورد استفاده قرار می‌گیرد (روی و سینک، ۲۰۰۶). مصرف بی‌رویه و زیاد کودهای شیمیایی مشکلات زیادی از جمله کاهش واکنش‌های گیاهان به کودها، بروز مشکلات زیست‌محیطی و اثرات سوء مواد شیمیایی بر کیفیت محصولات تولیدی و مواد غذایی، افزایش خطر باروری بالای خاک به علت تجمع بیش از حد کودهای شیمیایی در خاک و افزایش خطر مسمومیت، آلودگی منابع تأمین آب و به خطر افتادن سلامت انسان و پایین آمدن مقاومت گیاهان به آفات و بیماری‌ها می‌گردد (پاتل و همکاران، ۲۰۱۰).

کشاورزی اصولی و علمی تعیین تغییرپذیری ویژگی‌های خاک و بررسی عناصر موجود در خاک از اهمیت والایی برخوردار می‌باشد، زیرا به منظور دستیابی به عملکرد بیشتر و حفظ سلامت

محصولات کشاورزی و مدیریت کودی صحیح و جلوگیری از آلودگی خاک و آب لازم است تا اطلاعات کاملی از میزان عناصر غذایی خاک در دست باشد تا در راستای دستیابی به حداکثر بهره‌وری گامی اساسی برداشته شود. آب، خاک و هوا عناصر اصلی حیات بوده و حفاظت از آن‌ها ما را در تحقق توسعه پایدار راهنمایی می‌کند. بررسی و تهیه نقشه‌های حاصلخیزی خاک یکی از راه‌های اصلی حفاظت از خاک‌ها در مقابل مصرف بی‌رویه کودهای شیمیایی و یک راه‌کار اساسی در مصرف بهینه کودها در جلوگیری از آلودگی آب‌های زیرزمینی می‌باشد (داودی معمار و فلاح، ۱۳۹۲).

از آنجا که بشر همواره در تلاش برای یافتن راه‌حلهایی بوده تا پردازش اطلاعات، مسائل و پدیده‌هایی را که به راحتی قابل حل نیستند و همچنین یافتن روابط پیچیده میان پارامترهای پدیده‌های مورد نظر را در علوم مختلف تسهیل بخشد، با الگوبرداری از سیستم‌های بیولوژیک به سیستم‌های هوشمندی دست یافته است که قادر به استخراج دانش الگوریتم یا نگاشت از دل محاسبات عددی می‌باشد. در سال‌های اخیر روش‌های هوش مصنوعی در بسیاری از رشته‌های علمی به عنوان یکی از روش‌های سنتی آماری ارائه شده است. مطالعات اخیر نشان می‌دهد که مدل‌های هوش مصنوعی مانند روش‌های شبکه عصبی و منطق فازی به صورت موفقیت آمیز برای مدل‌سازی عناصر نادر خاکی در مناطق مختلف، مدل‌سازی آلودگی‌ها و پیش‌بینی پدیده‌های غیرخطی استفاده شده است (بانژاد و همکاران، ۲۰۱۳).

برتری روش تحلیل منطقه‌ای نسبت به دیگر روش‌ها را می‌توان در برآوردهای معتبر و قابل اطمینان دانست. در سال‌های اخیر، رویکرد استفاده از مدل هوشمند به عنوان فنون جدید و ابزاری توانمند در فرآیندهای آب‌شناختی و خاک‌شناسی نظیر پیش‌بینی، افزایش یافته است. زیرا این روش‌ها به عنوان جعبه سیاه مناسب، کم‌تر به ابزار و داده‌های مدل‌های فیزیکی نیاز داشته و قادرند فرآیند غیر خطی را مدل‌سازی کنند (شریفی و همکاران، ۱۳۹۳). سیستم استنتاج عصبی - فازی تطبیقی (ANFIS) یکی از روش‌های شبیه‌سازی است که در این روش از ترکیب منطق فازی و شبکه عصبی استفاده می‌شود که در آن از سیستم استنتاج فازی برای مدل کردن پدیده و از قابلیت شبکه عصبی



به منظور بهینه‌سازی پارامترهای آن استفاده می‌گردد. سیستم استنتاج عصبی - فازی تطبیقی نتایج خوبی در مدل‌سازی فرایندهای غیر خطی نشان داده و مشخصات سامانه را با توجه به داده‌های موجود آموزش و پارامترهای مربوطه را با توجه به معیار خطای مورد نظر تنظیم می‌کند (شریفی و همکاران، ۱۳۹۳). سیستم فازی یک سیستم مبتنی بر قواعد منطقی (شرط - نتیجه) است که با استفاده از مفهوم متغیرهای زبانی و روند تصمیم‌گیری فازی فضای متغیرهای ورودی را بر فضای متغیرهای خروجی تصویر می‌کند. ترکیب سیستم‌های فازی که مبتنی بر قواعد نطقی بوده و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش اطلاعات عددی را دارند منجر به ارائه سیستم استنتاج تطبیقی عصبی - فازی شده است (احمدزاده قره‌گویز و همکاران، ۱۳۸۹).

شبکه‌های عصبی مصنوعی با الگوبرداری از سیستم کارکرد مغز انسان، با پردازش داده‌های تجربی و بدون توجه به فیزیک مسئله قانون نهفته در ورای این اطلاعات را استخراج می‌کنند. در مقایسه با مدل‌های مرسوم، این مدل با ورودی کمتر به تلاش محاسباتی اندکی نیاز دارند. همچنین شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد. امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیندها در علوم مختلف بکار گرفته می‌شوند. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آنها است. ویژگی دیگر شبکه عصبی، تحمل‌پذیری در مقابل خطا می‌باشد. شبکه عصبی در پیشگویی متغیرهای پیوسته‌ای مانند رطوبت خاک، تخمین بیوماس و تخمین عملکرد نیز پتانسیل بالایی نشان داده است. مدل‌های شبکه عصبی دارای مزایایی از قبیل افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی می‌باشند (مکاریان و روحانی، ۱۳۹۲).

## ۱-۲ ضرورت تحقیق

با توجه به اینکه اندازه‌گیری برخی از عناصر غذایی پرمصرف و کم مصرف خاک زمان‌بر و هزینه‌بر بوده و همچنین نیاز به دستگاه‌های خاص و پیشرفته دارد، با توجه به این مسائل باید برای آن چاره‌ای اندیشیده شود. مدل‌های هوشمندی که امروزه از آن‌ها در تمام علوم استفاده‌های وافر می‌شود بستری را فراهم آورده است که بتوان از آن‌ها برای کاهش هزینه‌ها و صرفه‌جویی در زمان استفاده کرد. بنابراین در این تحقیق با استفاده از شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی - فازی تطبیقی (ANFIS) به پیش‌بینی دو عنصر کم مصرف روی و آهن‌خاک پرداخته شده است. پیش‌بینی این عناصر می‌تواند در مدیریت اراضی منطقه و مصرف بهینه کودهای شیمیایی مفید باشد.

## ۱-۳ روش انجام کار

بعد از جمع‌آوری داده‌های مورد نظر با استفاده از مدل شبکه عصبی مصنوعی (ANN) و شبکه عصبی - فازی تطبیقی (ANFIS) به مدل‌سازی و پیش‌بینی غلظت قابل جذب عنصر آهن و روی خاک اقدام گردید. بدین منظور از پارامترهای زودیافت خاک مانند آهک خاک، pH، EC و ماده آلی به عنوان ورودی به مدل استفاده شد. با استفاده از ورودی‌های مذکور ساختار مختلفی از شبکه‌های ANN و ANFIS توسعه و از توابع مختلف نیز استفاده گردید. برای اجرای مدل از یک ساختار یا چهارچوب که دارای یک لایه ورودی به تعداد مشخص پارامتر ورودی یک لایه خروجی و تعداد متفاوت از لایه میانی یا لایه پنهان (۱ الی ۱۰) می‌باشد. آنالیز دقیق و واقعی برای پیدا کردن تعداد نرون‌های لایه میانی در کل بسیار پیچیده است اما می‌توان گفت که تعداد نرون‌های لایه مخفی تابعی از تعداد عناصر برداری ورودی و همچنین حداکثر تعداد نواحی از فضای ورودی که بطور خطی از هم جداپذیرند می‌باشد. از این رو تعداد نرون‌های لایه مخفی عموماً بطور تجربی بدست می‌آید. پس از آن از تمامی توابع موجود در شبکه که شامل توابع انتقال سیگموئید، گوسین، تانژانت هایپربولیک، سکانت هایپربولیک بود، برای انتخاب نتایج بهترین تابع استفاده گردید. برای انجام مدل‌سازی داده‌ها باید به

سه صورت آموزش، اعتبار سنجی و آزمون تقسیم شدند، از مجموع داده‌های مورد استفاده ۶۶/۶۶ درصد آن برای آموزش مدل‌های طراحی شده ۱۶/۶۶ درصد برای اعتبارسنجی و ۱۶/۶۶ درصد مابقی برای آزمون اختصاص داده شدند. که از بین ۹۰ داده موجود، ۶۰ داده برای آموزش، ۱۵ داده برای اعتبارسنجی و ۱۵ داده برای آزمون به شبکه داده شد. همچنین به منظور مقایسه و تجزیه و تحلیل آماری، یعنی مقایسه بین عناصر اندازه‌گیری شده و برآورد شده توسط مدل‌های مورد نظر از معیارهای آماری که در زیر ارائه شده‌اند استفاده گردید:

بعد از آن با استفاده از معیارهای آماری مانند ضریب تبیین ( $R^2$ ).

$$R^2 = \frac{\left[ \sum_{i=1}^n (\hat{y}_i - \bar{y})(y_i - \bar{y}) \right]^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \sum_{i=1}^n (y_i - \bar{y})^2}$$

ریشه میانگین قدر مطلق خطا (RMSE)

$$RMSE = \left[ \frac{\sum_{j=1}^n (\hat{y}_j - y_j)^2}{n} \right]^{\frac{1}{2}}$$

از بین دو مدل ذکر شده بهترین مدل انتخاب گردید. بر اساس بهترین مدل انتخاب شده پیش‌بینی عناصر دیریافت خاک صورت پذیرفت، سپس با استفاده از مدل شبکه عصبی مصنوعی (ANN) و سیستم استنتاج تطبیقی عصبی فازی (ANFIS) به مدل‌سازی و پیش‌بینی عنصر روی و آهن اقدام گردید.

#### ۱-۴ اهداف

به کارگیری روشی کارآمد و کم‌هزینه جهت پیش‌بینی غلظت قابل جذب دو عنصر آهن و روی خاک.

بررسی عملکرد دو مدل شبکه عصبی و سیستم استنتاج تطبیقی عصبی- فازی.

مقایسه کارایی دو مدل شبکه عصبی و سیستم استنتاج تطبیقی عصبی- فازی و انتخاب

بهترین مدل جهت پیش‌بینی غلظت قابل جذب دو عنصر آهن و روی خاک.

# فصل دوم

## مرور بر منابع

## کلیات

### ۱-۲- تعریف خاک

خاک یکی از منابع مهم و طبیعی بوده و زیربنای تمدن و همچنین همه فعالیت‌های کشاورزی هر کشور است. به طوری که مسیر پیشرفت هر جامعه را اصول و چگونگی بهره‌برداری از خاک تعیین می‌کند (کریمی دهکردی و همکاران، ۱۳۹۳). کشاورزی به عنوان یکی از محورهای اساسی رشد و توسعه، نقش مهمی در توسعه اقتصادی کشورها دارد. در جهان امروز یک از مشکلات اساسی بشر تامین نیازهای غذایی به عنوان یکی از اهداف مهم سرلوحه برنامه‌های دولت قرار گرفته است. با گذشت زمان، مدیریت منابع به موازات رشد جوامع، پیچیده‌تر می‌شود و همزمان با افزایش جمعیت و رشد اقتصادی کشورها تقاضا برای مواد غذایی نیز رو به افزایش می‌باشد. پاسخگوی به این نیازها موجب به کارگیری ابزارهای مدرن و مواد شیمیایی جدید مانند انواع کودهای شیمیایی و سموم شده است. ولیکن استفاده بیش از حد و خارج از استاندارد این مواد شیمیایی موجب بروز آثار منفی جسمی برای مصرف کنندگان و آلودگی محیط زیست شده است (حسین‌زاده و همکاران، ۱۳۹۳). در کشور ما آهکی بودن خاک‌ها، پایین بودن ماده آلی، بالا بودن شوری آب آبیاری و خاک و وجود یون کربنات و بی‌کربنات در آب آبیاری باعث شده که حاصلخیزی خاک‌ها پایین باشد و کمبود عناصر غذایی مختلف عمومیت داشته باشد. در نتیجه تغذیه گیاهان و تامین مواد غذایی کافی یکی از عوامل شیمیایی ضروری در رشد و نمو گیاهان است. از این رو راه‌حلی که میزان عناصر غذایی خاک را به راحتی پیش‌بینی کند و باعث کاهش هزینه و صرفه‌جویی در زمان آن گردد می‌تواند در استفاده بجا و بهینه از کودهای شیمیایی در خاک‌هایی که با کمبود عناصر غذایی مواجه هستند کارآمد باشد. مدل‌های هوش مصنوعی مانند روش‌های شبکه عصبی و سیستم استنتاج عصبی - فازی تطبیقی به صورت موفقیت‌آمیز برای مدل‌سازی عناصر نادر خاکی در مناطق مختلف، مدل‌سازی آلودگی‌ها و پیش‌بینی پدیده‌های غیرخطی استفاده شده است (محمدی منور و باقرپور، ۱۳۹۶).

## ۲-۲ بررسی عناصر غذایی دیر یافت اندازه گیری شده

پارامترهایی که در این تحقیق اندازه گیری شده و به پیش بینی آن‌ها با مدل‌های شبکه عصبی و سیستم استنتاج تطبیقی عصبی- فازی پرداخته شده شامل خصوصیات فیزیکی از جمله بافت خاک، خصوصیات شیمیایی شامل اسیدپتته گل اشباع، هدایت الکتریکی، ماده آلی، آهک و عنصر کم مصرف آهن و روی می‌باشد.

### ۲-۲-۱- آهن

آهن از فلزات مهم و فراوان موجود در قسمت جامد زمین (لیتوسفر) می‌باشند. مقدار این عنصر در پوسته زمین ۵ درصد است. آهن در خاک‌های معدنی عمدتاً به فرم اکسید و هیدروکسیدها دانه‌ای کوچک و یا به صورت پوششی بر روی سطح مواد معدنی خاک وجود دارد. همچنین این عنصر در خاک‌های آلی به صورت کلات با مواد آلی وجود دارد (کاباتا پندایاس، ۲۰۱۱). وجود مقدار آهن کافی در گیاه برای سلامت گیاه و ذخیره عناصر غذایی برای انسان‌ها و حیوانات ضروری می‌باشد. آهن بخش تکمیل کننده ساختمان بسیاری از آنزیم‌های آنتی‌اکسیدانت است و یا در فعال سازی آن‌ها نقش دارد (مارشن، ۲۰۰۸). این عنصر جز ساختار سیتوکروم‌ها، فردوکسین‌ها و لگ‌هموگلوبین‌ها می‌باشد و در بسیاری از فعالیت‌های حیاتی گیاه از قبیل فتوسنتز، تنفس و تثبیت ملوکولی نیتروژن شرکت می‌کند. آهن در ساختمان پروتئین‌ها که پیش نیاز ساخت کلروفیل می‌باشند نیز وجود دارد (سلیمان‌زاده و همکاران، ۱۳۹۵).

مقدار آهن موجود در گیاه مختلف متغیر است و همواره به توانایی گیاه در جذب آهن بستگی ندارد و گاهی اوقات با توجه به شرایط خاک، آب، هوا و سن گیاه تغییر می‌کند. به طور کلی گیاهان خانواده لگومینوز بیشترین مقدار آهن را در بین گیاهان جذب می‌کنند. اگر آهن قابل دسترس در خاک فراوان باشد گیاه بیش از مقدار مورد نیاز خود آهن جذب می‌کند. کمبود آهن سبب بروز نشانه‌های زرد برگی (کلروز) می‌شود و از مهمترین عوامل تاثیر گذار بر عملکرد و کیفیت محصولات

کشاورزی سرتاسر جهان می‌باشد (کاکاک و همکاران، ۲۰۱۰). کمبود آهن در اغلب مناطق کشاورزی دنیا شایع است و با افزایش واکنش و آهک خاک این کمبود تشدید می‌شود (مارشن، ۲۰۰۸).

امروزه توجه کشاورزان و متخصصین علوم کشاورزی به اهمیت و نقش عناصر کم‌مصرف روز به روز بیشتر شده و این به دلیل پیدایش مسائل جدیدی از جمله برداشت روز افزون محصول و در نتیجه کاهش این عناصر در خاک است. کاهش عناصر غذایی در خاک به دلیل کاشت ارقام اصلاح شده، مصرف کودهای شیمیایی و مدیریت بهتر تولید است که مجموعه این موارد باعث کاهش عناصر کم‌مصرف در خاک است (ملکوتی و غیبی، ۱۳۸۴).

## ۲-۲-۲ روی

عنصر روی یکی از عناصر مهم و ضروری در فرایند رشد و نمو در گیاهان و جانوران می‌باشد، چرا که این عنصر در بسیاری از واکنش‌های آنزیمی، فرایندهای متابولیکی و همچنین واکنش‌های اکسایش-کاهش نقش اساسی ایفا می‌کند. علاوه بر این، عنصر روی (Zn) در ساختار بسیاری از آنزیم-های دخیل در فرایندهای متابولیسم نیتروژن، انتقال انرژی و سنتز پروتئین نقش اساسی دارد. کمبود روی در گیاهان فرایندهای رشد و نمو را تحت‌تأثیر قرار داده و به تعویق می‌اندازد و باعث کاهش شدید محصول می‌گردد (حافظ و همکاران، ۲۰۱۳).

عنصر روی با تحت‌تأثیر قرار دادن فعالیت‌های آنزیم‌های هیدروژناز و کربونیک انیدراز، تثبیت ساختارهای ریبوزومی و سنتز سیتوکروم، نقش بسیار مهمی در متابولیسم گیاه بازی می‌کند. آنزیم-های گیاهی که توسط روی فعال می‌شوند عمدتاً در متابولیسم قندها، حفظ یکپارچگی ساختار غشای سلولی، سنتز پروتئین، تنظیم سنتز هورمون اکسین و تشکیل گرده، دخیل هستند. در گیاهان، تنظیم بیان ژن که نقش مهمی در تحمل استرس‌های محیطی دارد، به وجود این عنصر وابسته است (حافظ و همکاران، ۲۰۱۳). نبود یا کمبود روی در گیاهان منجر به بروز ناهنجاری‌هایی در گیاهان می‌شود که علائم خارجی آن‌ها بصورت نشانه‌هایی چون کاهش شدید رشد گیاه، کلروز برگ و کوچک شدن



برگ‌ها و همچنین عقیمی گیاه، دیده می‌شود. کمبود عنصر روی که از عناصر کم مصرف به حساب می‌آید، می‌تواند کیفیت محصولات جمع آوری شده از سطح مزرعه و باغ را نیز تحت تاثیر قرار دهد. به این صورت که گیاه دچار ضعف شده و به سادگی با قرار گرفتن در معرض نور شدید و یا افزایش دما دچار آسیب می‌شود، علاوه براین، در چنین حالتی تاثیر آسیب‌های ناشی از حمله قارچ‌ها و بیماری‌ها به مراتب بیشتر خواهد بود (اصیف و همکاران، ۲۰۱۷).

برخی از تحقیقات نشان می‌دهند که این عنصر توان جذب و انتقال آب توسط گیاهان را تحت تاثیر قرار داده و همچنین تا حدی اثرات بد استرس‌های کوتاه مدت شوری و گرما را مرتفع می‌سازد. از آنجا که عنصر روی یک فاکتور بسیار کلیدی در سنتز اسید آمینه تریپتوفان می‌باشد، و این اسید آمینه از پیش سازهای (ایندول استیک اسید) می‌باشد، بنابراین می‌توان این گونه نتیجه‌گیری کرد که، این عنصر نقش پررنگی در تولید هورمون اکسین، که از هورمون‌های رشد می‌باشد، دارد. از دیگر نقش‌های این عنصر مهم می‌توان به حفظ یک پارچگی غشاهای سلولی اشاره کرد. این عنصر به حفظ موقعیت ساختاری ماکرومولکول‌ها درون غشا و همچنین سیستم‌های انتقال یون کمک می‌کند. میانکنش این عنصر با فسفولیپیدها و گروه‌های سولفیدریل پروتئین‌های غشایی، به حفظ یکپارچگی غشا کمک می‌کند (کاکاک و همکاران، ۲۰۱۷).

کمبود این عنصر در انسان، اثرات خود را در فرایندهای رشدی به وضوح نشان خواهد داد. براساس گزارش‌های موجود، بیش از سه میلیارد نفر در سراسر جهان از کمبود آهن و روی رنج می‌برند و این وضعیت خصوصا در مناطقی به چشم می‌آید که مردم عمدتا از برنامه‌های غذایی کاملا یک‌نواخت بر پایه غلات بدون سبوس استفاده می‌کنند. عمده عنصر آهن و روی در سبوس غلات ذخیره می‌شود که این جز با ارزش عمدتا طی فرایند آسیاب کردن از غلات جدا می‌شود (کاکاک و همکاران، ۲۰۱۷).

## ۲-۳ تعامل عنصر روی و آهن

میان کنش بین عنصر روی و آهن نیز تا حدی پیچیده است. افزایش استفاده از عنصر روی تا حدی بر روی غلظت آهن موجود در جوانه‌ها اثر گذاشته و موجب کاهش آن می‌شود. متعاقباً، سطوح بالای آهن به طور معمول بر روی غلظت روی موجود در بافت‌های گیاهی یک اثر سرکوبی دارد هرچند نتایج تحقیقات نشان می‌دهد که این افزایش غلظت آهن اثری در جذب روی توسط ریشه‌ها ندارد. وجود این همه اطلاعات متناقض احتمالاً ناشی از اختلاف در شرایط آزمایش و همچنین تفاوت در گونه‌های مختلف گیاهی می‌باشد. به طور کلی کمبود آهن موجب افزایش غلظت روی در جوانه‌های گیاهان و همچنین افزایش شدت جذب روی در گیاهان علفی و دو لپه‌ای‌ها می‌شود. احتمالاً در گیاهان دو لپه‌ای، مکانیسم افزایش جذب روی از طریق اسیدی کردن ریزوسفر می‌باشد که این امر موجب کاهش سطح جذب آهن می‌گردد. در گیاهان علوفه‌ای، رهاسازی فیتوسیدروفورها در شرایط کمبود روی پاسخی است از طرف گیاه که موجب افزایش شدت جذب این عنصر ارزشمند از خاک می‌گردد چرا که ساختارهای فیتوسیدروفور موجب افزایش حرکت یون روی در خاک‌های آهکی می‌شوند. به طور مشابه، در گیاه لوبیا و ذرت تحت شرایط کمبود روی، در پی اسیدی شدن ریزوسفر و آزاد شدن ترکیبات احیا کننده و فیتوسیدروفورها، یون‌های آهن درون جوانه‌ها تجمع می‌یابند (حافظ و همکاران، ۲۰۱۳).

## ۲-۴ اهمیت عناصر غذایی مذکور و روابط آن‌ها با ویژگی‌های خاک

اندازه‌گیری عناصر غذایی خاک چه در آزمایشگاه و چه در صحرا غالباً هزینه‌بر و وقت‌گیر است. توابع انتقالی روشی غیرمستقیم برای برآورد ویژگی‌های دیریافت خاک مانند برخی از عناصر غذایی خاک با استفاده از پارامترهای زودیافت خاک می‌باشند که علاوه بر دقت مناسب دارای ویژگی صرفه‌جویی در زمان و هزینه هستند. توابع انتقالی به روش‌های رگرسیون چندگانه و شبکه عصبی مصنوعی، ارتباط میان پارامترهای زودیافت و دیریافت را بیان می‌کنند. در دهه اخیر مدل‌های مبتنی

بر هوش مصنوعی به تدریج جایگاه مناسبی در حل مسائلی از این دست به دست آورده‌اند. شبکه‌های عصبی مصنوعی، سیستم استنتاج فازی (FIS) و همچنین مدل‌های نروفازی (ANFIS) که تلفیقی از دو روش یاد شده هستند توسط محققین به منظور مدل‌سازی‌ها و پیش‌بینی پدیده‌های مختلف به کار برده شده‌اند (ولونساس و پاردیلیس ۲۰۱۷، مزاک و همکاران ۲۰۱۷، طاهری راد و همکاران ۲۰۱۷) برای ارتباط دادن متغیرها با میزان عناصر خاک روش‌های مختلفی وجود دارد، یکی از راه‌های درک بهتر روابط موجود بین ویژگی‌های خاک و ارزیابی تاثیر متقابل آن‌ها برهم مدل‌سازی می‌باشد. برای ساخت یک مدل، راهکارهای گوناگونی وجود دارد که پژوهشگر براساس نوع مساله و ویژگی‌های موضوع مورد مطالعه به انتخاب یکی از آن‌ها می‌پردازد. از آن جمله می‌توان به رگرسیون خطی چندمتغیره و تکنیک‌های هوش محاسباتی (تلفیق شبکه‌های عصبی و سامانه‌های فازی) اشاره کرد (بانژاد و همکاران، ۲۰۱۳).

یکی دیگر از روش‌های مدل‌سازی استفاده از رابطه همبستگی می‌باشد. تحلیل همبستگی به طور عمده به منظور پیش‌بینی مقادیر متغیر وابسته توسط مقادیر متغیر مستقل مورد استفاده قرار می‌گیرد. در مطالعه ارتباط خطی بین دو یا چند متغیر، همبستگی خطی وسیع‌ترین مدل مورد استفاده می‌باشد (بانژاد و همکاران، ۲۰۱۳).

## ۲-۵ شبکه عصبی مصنوعی (ANN)

اولین سلول عصبی مصنوعی در سال ۱۹۴۳ با الهام از سلول‌های عصبی واقعی بوسیله یک متخصص فیزیولوژی اعصاب به نام Warren McCulloch و یک استاد منطق به نام Walter Pitts ساخته شد. اما محدودیت‌های تکنولوژی در آن زمان اجازه کار بیشتر به آن‌ها نداد (امیرانتظاری و همکاران، ۱۳۸۸).

شبکه عصبی مصنوعی را می‌توان مدل‌های سخت‌افزاری از ساختار عصبی مغز انسان نامید. مکانیسم فراگیری و آموزش مغز اساساً بر تجربه استوار است. شبکه عصبی مصنوعی نیز بر اساس الگو

بنا شده‌اند و روش پردازش اطلاعات در چنین مدل‌های، با روش‌های محاسباتی که در سیستم کامپیوترهای دیجیتال در پیش گرفته شده‌اند تفاوت دارد. می‌دانیم که حتی ساده‌ترین مغزهای جانوری هم قادر به حل مسائل مختلف شناسایی الگو نمونه‌ای از مواردی هستند که روش‌های معمول محاسباتی برای حل آنها کارایی چندانی ندارند، در حالی که مغز ساده‌ترین جانوران به راحتی از عهده چنین مسائلی بر می‌آید. یک شبکه عصبی مصنوعی از شمار زیادی عناصر پردازشی فوق‌العاده بهم پیوسته تشکیل شده (neurons) که برای حل یک مساله به طور هماهنگ عمل می‌کند. این شبکه‌ها نظیر انسان‌ها مثال یاد می‌گیرند. مقادیر عناصر یک شبکه برای انجام وظیفه‌ای مشخص مانند شناسایی الگوها و دسته‌بندی اطلاعات در طول یک پروسه یادگیری تنظیم می‌شود. در سیستم زیستی یادگیری با تنظیماتی در اتصالات سیناپسی که بین اعصاب قرار دارد همراه است در حالی که عمل یادگیری با تغییر وزن‌های بین نرون‌های یک شبکه عصبی مدل می‌باشد (امیرانتظاری و همکاران، ۱۳۸۸).

شبکه عصبی مصنوعی با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند که به این عمل یادگیری می‌گویند. اصولاً توانایی یادگیری مهمترین ویژگی یک سیستم هوشمند است. سیستمی که بتواند یاد بگیرد منعطف‌تر است و ساده‌تر برنامه‌ریزی می‌شود بنابراین بهتر می‌تواند در مورد مسایل و معادلات جدید پاسخگو باشد (چکسوی و همکاران، ۲۰۱۷). انسان‌ها از زمان‌های بسیار دور سعی بر آن داشتند که بیوفیزیولوژی مغز را دریابند چون همواره مسئله هوشمندی انسان و قابلیت یادگیری، تعمیم، خلاقیت، انعطاف‌پذیری و پردازش موازی در مغز برای بشر جالب بوده و بکارگیری این قابلیت‌ها در ماشین‌ها بسیار مطلوب می‌نمود. روش‌های الگوریتمیک برای پیاده‌سازی این خصایص در ماشین‌ها مناسب نمی‌باشند در نتیجه می‌بایست روش‌های مبتنی بر همان مدل‌های بیولوژیکی باشند. به عبارت دیگر شبکه عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچک و بسیار زیادی سپرده که به صورت شبکه‌ای به هم پیوسته و موازی با یکدیگر رفتار می‌-

کنند تا یک مسئله را حل نمایند. در این شبکه‌ها به کمک دانش برنامه نویسی، ساختار داده‌ای طراحی می‌شود که می‌توانند همانند نورون عمل کند. به این ساختار داده گره گفته می‌شود. سپس با ایجاد شبکه‌ای بین این گره‌ها و اعمال یک الگوریتم آموزشی به آن، شبکه را آموزش می‌دهند. در این حافظه یا شبکه عصبی گره‌ها دارای دو حالت فعال و غیرفعال‌اند و هر یال (سیناپس یا ارتباط بین گره‌ها) دارای یک وزن می‌باشد. یال‌های با وزن مثبت، موجب تحریک یا فعال کردن گره غیر فعال بعدی می‌شوند و یال‌های با وزن منفی، گره متصل بعدی را غیر فعال یا مهار می‌کنند (فرنج و همکاران، ۲۰۱۷).

## ۲-۵-۱ توانایی‌های شبکه عصبی

شبکه عصبی با توانایی قابل توجه خود در استنتاج نتایج از داده‌هایی پیچیده، می‌تواند در استخراج الگوها و شناسایی گرایش‌های مختلفی که برای انسان‌ها و کامپیوتر شناسایی آن‌ها بسیار دشوار است استفاده شوند از مزایای شبکه عصبی می‌توان به موارد زیر اشاره کرد.

## ۲-۵-۱-۱ یادگیری تطبیقی

استخراج نتایج تحلیلی از یک نگاشت غیرخطی که با چند مثال مشخص شده است، کار ساده‌ای نیست. نرون یک دستگاه غیرخطی است و در نتیجه یک شبکه عصبی که از اجتماع این نرون‌ها تشکیل می‌شود نیز یک سیستم کاملاً پیچیده و غیرخطی خواهد بود. به علاوه خاصیت غیر خطی عناصر پردازش در کل شبکه توزیع می‌گردد. پیاده‌سازی یک سیستم با یک نگاشت غیرخطی و یا خطی پیچیده به وسیله یک الگوریتم معمولی و بدون قابلیت یادگیری نیاز به دقت و مراقبت زیادی دارد. در چنین حالتی سیستمی که بتواند خود این رابطه را استخراج کند، بسیار سودمند به نظر می‌رسد. خصوصاً افزودن مثال‌های احتمالی در آینده به یک سیستم با قابلیت یادگیری، به مراتب آسان‌تر از انجام آن در یک سیستم بدون چنین قابلیت است. قابلیت یادگیری یعنی توانایی تنظیم پارامترهای شبکه (وزنهای سیناپسی)، هنگامی که محیط شبکه تغییر می‌کند و شبکه شرایط جدید را

تجربه می‌کند. با این هدف که اگر شبکه برای یک وضعیت خاص آموزش دید و تغییر کوچکی در شرایط محیطی آن (وضعیت خاص) رخ داد، شبکه بتواند با آموزش مختصر برای شرایط جدید کارآمد باشد. دیگر اینکه اطلاعات در شبکه‌های عصبی در سیناپس‌ها ذخیره می‌گردد و هر نرون در شبکه به صورت بالقوه از کل فعالیت سایر نرون‌ها متأثر می‌شود. در نتیجه اطلاعات از نوع مجزا از هم نبوده بلکه متأثر از کل شبکه است. آنچه که شبکه عصبی فرا می‌گیرد اطلاعات و یا دانش، در وزن‌های سیناپسی مستتر می‌باشد. رابطه یک به یک بین ورودی‌ها و وزن‌های سیناپسی وجود ندارد. می‌توان گفت که هر وزن سیناپسی مربوط به همه ورودی‌ها است ولی به هیچ یک از آنها به طور منفرد و مجزا مربوط نیست. به عبارت دیگر هر نرون در شبکه، از کل فعالیت سایر نرون‌ها متأثر می‌باشد. در نتیجه اطلاعات توسط شبکه‌های عصبی پردازش می‌شوند. براین اساس، چنانچه بخشی از سلول‌های شبکه حذف شوند و یا عملکرد غلط داشته باشند باز هم احتمال رسیدن به پاسخ صحیح وجود دارد. اگر چه این احتمال برای تمام ورودی‌ها کاهش یافته، ولی برای هیچ یک از بین نرفته است (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۱-۲ 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 (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۱-۳ عملکردهای بلادرنگ

محاسبات در شبکه عصبی مصنوعی می‌توان به صورت موازی و به وسیله سخت‌افزارهای مخصوصی که طراحی و ساخت آن برای دریافت نتایج بهینه قابلیت‌های شبکه عصبی مصنوعی است انجام شد (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۱-۴ تحمل خطا

در یک شبکه عصبی مصنوعی هر سلول به طور مستقل عمل می‌کند و رفتار کلی شبکه برآیند رفتارهای محلی سلول‌های متعدد است. این ویژگی باعث می‌شود تا خطاهای محلی از چشم خروجی نهایی دور بماند. به عبارت دیگر سلول‌ها در یک روند همکاری، خطاهای محلی یکدیگر را تصحیح می‌کنند. این خصوصیت باعث افزایش قابلیت مقاوم بودن (تحمل پذیری خطاها) در سیستم می‌گردد (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۱-۵ دسته بندی

شبکه‌های عصبی قادر به دسته‌بندی ورودی‌ها برای دریافت خروجی مناسب می‌باشند (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۱-۶ تعمیم دهی

این خاصیت شبکه را قادر می‌سازد تا تنها برخورد با تعداد محدود 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 سیستم باید بی‌نهایت واقعیت‌ها و روابط را به خاطر بسپارد (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۱-۷ 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 می‌توان موارد جدید را پذیرفت (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۲ آموزش شبکه‌های عصبی

هدف استفاده از شبکه عصبی مصنوعی برای حل یک مسئله، بدست آوردن خروجی مناسب با توجه به داده‌های ورودی است. حال اینکه مقدار خروجی بدست آمده چقدر با مقداری واقعی آن اختلاف

دارد، بستگی به آموزش شبکه و انتخاب وزن‌ها و بایاس‌های مناسب برای لایه‌ها دارد نحوه یادگیری در شبکه‌های عصبی به دو صورت انجام می‌گیرد (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۲-۱ آموزش با ناظر

معمولا برای آموزش شبکه مجموعه زوج نیروهای ورودی و خروجی به آن اعمال می‌شود. هر کدام از این دسته‌های ورودی و خروجی را می‌توان به صورت یک بردار در نظر گرفت. سپس شبکه با اعمال تنظیم وزن‌های شبکه آموزش می‌بیند. طی آموزش شبکه، وزن‌های شبکه به تدریج به مقادیری همگرا می‌شوند که به ازای آنها با اعمال یک بردار ورودی، بردار خروجی دلخواه تولید می‌گردد. این گونه آموزش را آموزش با ناظر می‌نامیم (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۲-۲ آموزش بدون ناظر

در این نوع آموزش فقط بردارهای ورودی به شبکه داده می‌شود و جواب مطلوب بر شبکه اعمال نمی‌شود در این حالت شبکه رابطه بین ورودی‌ها را پیدا می‌کند و گروه‌بندی کرده در خروجی کد می‌کند. به علت سرعت قابل بوجهی که این نوع شبکه در هنگام آموزش نسبت به آموزش با ناظر دارند این شبکه‌ها را برای حل مسائل عملی متمایز کرده است (مصطفی بیگدلی، ۲۰۱۰).

## ۲-۵-۳ انواع شبکه عصبی

- ۱- پرسپترون چند لایه یا MLP
- ۲- شبکه‌های عصبی شعاعی یا RBF
- ۳- ماشین‌های بردار پشتیبان یا SVM
- ۴- نگاشت‌های خود سازمان‌دهنده یا SOM
- ۵- یادگیرنده رقمی ساز بردار یا LVQ
- ۶- شبکه عصبی هاپفیلد یا Hopfield



در پژوهش‌های مختلفی از شبکه برای پیش‌بینی ویژگی‌های مختلف خاک استفاده شد. تانگ و همکاران (۲۰۰۸) با استفاده از شبکه‌های عصبی توابع پایه شعاعی برای قابلیت تبادل کاتیونی استفاده کردند و دریافتند که شبکه‌های عصبی پیش‌بینی این پارامتر را با دقت بیشتر نسبت به مدل‌های رگرسیونی چند متغیره پیش‌بینی می‌کنند. عملکرد مدل‌های شبکه عصبی مصنوعی و رگرسیونی چند متغیره خطی با استفاده از دسته داده‌های آزمونی مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل شبکه عصبی پس انتشار خطای توسعه داده شده با چهار ورودی کربن‌آلی، رطوبت اشباع، درصد رس و شن با هفت نرون در لایه پنهان توانست ظرفیت تبادل کاتیونی را بهتر از مدل‌های رگرسیونی و دیگر مدل‌های شبکه عصبی مصنوعی پیش‌بینی کند.

ابراهیم اکماج (۲۰۱۰) در پژوهشی به مقایسه برآورد ماده‌آلی ذره‌ای (POM) خاک در حوزه آبخیز منج توسط ۱۳ پارامتر سهل الوصول با استفاده از شبکه‌های عصبی مصنوعی، رگرسیون و روش معکوس فاصله (IDW) پرداختند. مقادیر ماده‌آلی ذره‌ای توسط شبکه‌های عصبی مصنوعی در نرم‌افزار مطلب برآورد گردید. نتایج بیانگر دقت بالای شبکه‌های عصبی مصنوعی در برآورد POM نسبت به روش‌های دیگر بود.

بازوبندی و همکاران (۱۳۹۴) در تحقیقی با استفاده از پارامترهای شن، سیلت، رس، کربن آلی، EC و pH، غلظت کادمیم و سرب کل خاک را به کمک شبکه عصبی تخمین زدند که با توجه به میزان خطا و ضریب تبیین، شبکه عصبی مصنوعی کارایی بسیار بالایی در تخمین کادمیم کل داشت. همچنین نتایج این پژوهش نشان داد که مدل در مرحله آموزش کارایی بالاتری نسبت به مرحله آزمون داشت و در کل روش مناسبی برای تخمین عناصر سنگین تلقی گردید.

طبری و همکاران (۲۰۱۱) به مقایسه عملکرد شبکه عصبی مصنوعی از نوع پرسپترون چند لایه با روش رگرسیون خطی چند متغیره برای برآورد دمای روزانه خاک در عمق‌های ۵، ۱۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری در منطقه خشک ایران پرداختند. برای ورودی دو مدل شبکه عصبی و رگرسیون

خطی چندگانه از میانگین روزانه پارامترهای هواشناسی که شامل دما، تابش خورشیدی و رطوبت نسبی بود، استفاده شد. نتایج مقایسه بین این دو مدل نشان داد که شبکه عصبی مصنوعی دقت بالاتری را در برآورد دمای روزانه خاک در منطقه مورد مطالعه داراست.

داوری و همکاران (۲۰۱۵) در یک مطالعه عملکرد شبکه عصبی از طریق پارامترهای چون جذر میانگین مربع خطا (RMSE) و ضریب همبستگی بین خروجی‌های حقیقی و شبیه‌سازی شده (R)، سنجیده شد. نتایج تحقیق نشان داد در بهترین ساختار شبکه، ضریب همبستگی بین مقادیر شبیه‌سازی شده و مقادیر واقعی ۰/۷۵ است. همچنین عوامل شوری آب سطحی، قابلیت انتقال تشکیلات آبخوان (بافت و نوع تشکیلات) و فاصله از دریا، بهترین ورودی‌ها برای شبیه‌سازی شوری آب زیرزمینی در سواحل استان مازندران هستند.

مزاکی و همکاران (۲۰۱۷) طی یک پژوهش خطر تغییر کاربری زمین در یک منطقه پر جمعیت در شمال ایتالیا، منطقه میلان و مونزا و بریانزا، با استفاده از مدل مبتنی بر شبکه‌های عصبی مصنوعی به عنوان روش وزن‌گیری و روش همبستگی فضایی به عنوان روش خوشه‌ای، مورد تحلیل قرار دادند. نتایج نشان می‌دهد خطرات عمده مربوط به تغییر کاربری زمین‌های کشاورزی به فضای شهری است، که توسط یک نقشه اطلاعات جغرافیایی (GIS) تجسم شده است

چوودوری و همکاران (۲۰۱۷) طی یک پژوهش برای پیش‌بینی کل غلظت مواد جامد محلول (TDS) آب‌های زیرزمینی ناحیه نادیا، بنگال غربی از روش شبکه عصبی مصنوعی استفاده نمودند. ساختار شبکه‌های عصبی چند لایه (MLP) با ترکیبی از پارامترهای ورودی در این مطالعه برای پیش‌بینی TDS در منطقه مورد مطالعه مورد بررسی قرار گرفت. تعداد قابل توجهی از آزمایشات نشان داد که 3 گره در لایه ورودی، 20 گره در لایه پنهان و یک گره در لایه خروجی بیشترین  $R^2$  و کمترین RMSE را به خود اختصاص داد.

پنتوس و پایکزارکا (۲۰۱۷) طی یک پژوهش به بررسی تاثیر بافت خاک، رطوبت خاک، تراکم و همچنین تغییر شکل افقی و بار عمودی بر نیروی کشش و کارایی کشش با استفاده از شبکه‌های عصبی مصنوعی پرداختند. مدل‌های دقیق ریاضی با ضریب تبیین ( $R^2$ ) برای مجموعه داده‌های اعتبارسنجی ۰/۹۴ برای نیروی کشش و ۰/۹۶ برای کارایی کشش بدست آمد. بر اساس مدل عصبی، تجزیه و تحلیل سهم متغیرهای ورودی مستقل انجام شد. بافت خاک و رطوبت خاک بیشترین تاثیر را در نیروی کشش و کارایی کشش داشتند. بار عمودی به طور قابل توجهی نیروی کشش را تحت تاثیر قرار داد. تغییر شکل افقی و تراکم خاک تاثیرات جزئی بر هر دو متغیر وابسته دارد.

فریت و همکاران (۲۰۰۳) از شبکه‌های عصبی مصنوعی با ساختار پرسپترون چند لایه با دو لایه پنهان و تابع عملگر سیگموئید به منظور برآورد رطوبت خاک استفاده کردند و دریافتند که شبکه‌های عصبی که از چنین ساختاری بهره می‌برند ابزار مناسبی برای تخمین رطوبت خاک هستند. . تانگ و همکاران (۲۰۰۸) از شبکه‌های عصبی توابع پایه شعاعی برای پیشبینی ظرفیت تبادل کاتیونی استفاده کردند و دریافتند که شبکه‌های عصبی ظرفیت تبادل کاتیونی را با دقت بیشتر نسبت به مدل‌های رگرسیونی چند متغیره پیشبینی میکنند. نستور (۲۰۰۶) از مدل شبکه عصبی پرسپترون چند لایه در پیش بینی نفوذپذیری خاک در فیلیپین استفاده کرد. شبکه‌های مورد استفاده به طور متوسط دارای ضریب تعیین بالایی با میانگین ۰/۹۱۱ بودند. آنالیز حساسیت نشان داد که رطوبت خاک و هدایت هیدرولیکی فاکتورهای مؤثر در پیش بینی مدل نفوذ با استفاده از شبکه‌های عصبی می‌باشند.

معماریان فرد و بیگی (۱۳۸۸) طی یک پژوهش به مقایسه مدل‌های شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی برای پیش‌بینی ظرفیت تبادل کاتیونی خاک‌های استان چهارمحال بختیاری پرداختند. بدین منظور ۲۰۰ نمونه خاک به دو دسته ۱۶۵ تایی برای توسعه مدل و ۳۵ تایی برای ارزیابی مدل تقسیم شدند. دقت پیش‌بینی بوسیله آماره‌های ضریب تعیین ( $R^2$ ) و ریشه میانگین

مربعات خطا بین CEC اندازه‌گیری و پیش‌بینی شده ارزیابی شد. نتایج نشان داد هنگامی که از شبکه عصبی با یک لایه پنهان و هفت نرون در این لایه و ماده آلی، درصد رطوبت اشباع، درصد رس و شن به عنوان ورودی استفاده کردند. CEC با  $R^2 = 0/81$  و  $RMSE = 3/05$  سانتی‌مول بر کیلوگرم خاک بهتر از دیگر مدل‌ها پیش‌بینی شد. مقادیر ضریب تعیین و ریشه دوم میانگین مربعات خطا به ترتیب از  $0/66$  تا  $0/69$  و از  $4/26$  تا  $4/69$  برای روش رگرسیونی و از  $0/78$  تا  $0/81$  و  $3/29$  تا  $3/05$  برای شبکه عصبی متغیربود. نتایج نشان داد که پیش‌بینی شبکه عصبی بهتر از تابع‌های رگرسیونی می‌باشد.

## ۲-۶ سیستم استنتاج تطبیقی عصبی-فازی (ANFIS)

در بین روش‌های نوین مدل‌سازی، سامانه‌های فازی از جایگاه ویژه‌ای برخوردار است. توانایی پیاده‌سازی دانش بشری با استفاده از مفاهیم برچسب‌های زبانی و قواعد فازی، غیرخطی بودن و قابلیت سازش‌پذیری این سیستم‌ها و دقت بهتر آن‌ها در مقایسه با سایر روش‌ها در شرایط محدودیت داده‌ها، از جمله مهمترین ویژگی‌های این سیستم‌ها می‌باشد (شریفی و همکاران، ۱۳۹۳). نکته مهم منطق فازی، امکان برقراری ارتباط بین فضای خروجی است و سازوکار اولیه برای انجام این کار فهرستی از جملات If-Then است، که قانون نامیده می‌شوند. داشتن روشی که با استفاده از آن بتوان اطلاعات موجود برای ساخت این قواعد را استفاده کرد به عنوان ابزاری کارآمد بشمار می‌رود. از طرفی، شبکه‌های عصبی مصنوعی به دلیل قابلیت‌های آموزش‌پذیری با استفاده از الگوهای مختلف آموزشی می‌تواند ارتباط مناسبی بین متغیرهای ورودی و خروجی ایجاد نماید. لذا استفاده ترکیبی از سامانه استنباط فازی و شبکه عصبی مصنوعی به عنوان ابزاری قدرتمند که قابلیت پیش‌بینی نتایج با استفاده از داده‌های عددی موجود را دارند، تحت عنوان سامانه استنتاج تطبیقی عصبی فازی معرفی می‌شود. اولین بار جانگ در سال ۱۹۹۳ توانست از قدرت زبانی سیستم‌های فازی و آموزش شبکه‌های عصبی استفاده نماید و سیستمی تحت عنوان سیستم‌های فازی بر پایه شبکه عصبی تطبیقی ارائه نماید

(جانگ و همکاران، ۱۹۹۳). تمرکز تحقیقات بر روی شبکه عصبی از یک رویکرد جعبه سیاه (Black-Box) به معماری عصبی-فازی دینامیکی توسعه یافته است (ایمانی و همکاران، ۱۳۹۵). غالباً سیستم‌های انفیس را با استفاده از یک سیستم فازی تاکاگی-سوگنو-کانگ (TSK) به صورت ساختار شبکه‌ای پیش‌رونده به کار می‌برند. خروجی مدل TSK با انجام درون‌یابی‌ها فازی و در نظر گرفتن همسایگی فازی محاسبه می‌شود. مزیت قابل توجه مدل‌های TSK، توانایی آن‌ها برای تعیین دقت مدل‌سازی یک سیستم در هر دو سطح کلی و محلی می‌باشد (کوئک و کوئک، ۲۰۰۶). سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) از جمله مدل‌های TSK است که با تنظیم پارامترهای کلی و به حداقل رساندن خطاهای کلی اجرا می‌شود (جانگ، ۱۹۹۳).

کریمی و گلابی (۲۰۱۳) طی یک پژوهش با شبیه‌سازی و پیش‌بینی پارامترهای کیفیت آب را با استفاده از شبکه‌های عصبی مصنوعی، روش فازی-عصبی و رگرسیون آماری برای رودخانه کارون در استان نشان دادند که شبکه‌های عصبی مصنوعی و فازی-عصبی تخمین مطلوب‌تری در شبیه‌سازی و برآورد SAR، TDS و EC دارد.

اعلایی و همکاران (۲۰۱۵) طی یک پژوهش به منظور پیش‌بینی کیفیت آب دشت نیشابور با استفاده از شبکه عصبی MLP و سیستم استنتاج عصبی-فازی تطبیقی به ارزیابی و پیش‌بینی میزان مواد جامد محلول (TDS) دشت نیشابور با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی تطبیقی و به کمک داده‌های کمی کیفی دبی جریان، دما، کربنات، بی‌کربنات، و مقادیر یونی کلر، سولفات، کلسیم، منیزیم و سدیم پرداختند.

کیسی و همکاران (۲۰۱۷) در یک پژوهش کاربرد شبکه‌های عصبی مصنوعی (ANN)، سیستم استنتاج فازی-عصبی (ANFIS) و تکنیک‌های برنامه نویسی ژنتیکی (GP) را در تخمین دمای خاک (ST) در عمق‌های مختلف مورد بررسی قرار دادند. داده‌های هواشناسی از دو ایستگاه، مرسین و آدانا، در ترکیه به عنوان ورودی برای مدل‌های کاربردی به منظور مدل‌سازی ماهانه استفاده

شده است. قسمت اول مطالعه، مقایسه مدل‌های ANN، ANFIS و GP در مدل سازی ST از دو ایستگاه در عمق ۱۰، ۵۰ و ۱۰۰ سانتی متر بود. نتایج نشان داد که مدل GP برآورد ماهانه ST را بهتر از ANN و ANFIS-SC انجام داد. اثر دوره (ماه سال) بر دقت مدل نیز مورد بررسی قرار گرفتند. بخش دوم مطالعه، دقت و صحت مدل‌های ANN، ANFIS و GP در تخمین ST ایستگاه مرسین با استفاده از داده‌های آب و هوایی ایستگاه اادانا مقایسه شد. مدل‌های ANN به طور کلی بهتر از ANFIS-SC و GP در مدل سازی ST ایستگاه مرسین بدون ورودی‌های محلی آب و هوایی بوده است.

محمدی سلطان آباد و همکاران (۱۳۹۲) طی یک پژوهش سعی بر آن داشتند که با مقایسه روش‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی میزان فرسایش و رسوب را در حوضه نوران برآورد کنند. در این پژوهش فاکتورهای موثر در فرسایش در طی دوره آماری سال ۱۳۷۰ تا ۱۳۸۸ ابتدا نرمالیزه گردید و هر دو مدل مورد تحلیل و بررسی قرار گرفت. خروجی حاصل از شبکه عصبی مصنوعی با ۶ نرون در لایه میانی ۰.۸۶٪ است که بالاترین دقت شبیه‌سازی و هم‌بستگی شبکه در این پژوهش است. توانایی سیستم شبکه عصبی مصنوعی در پیش بینی فرسایش در دوره زمانی ۵ ساله برابر با ۰/۹۰ است و توانایی سیستم استنتاج عصبی- فازی تطبیقی (ANFIS) در مدل سازی و پیش‌بینی با اطمینان ۰/۹۲/۹۹٪ مورد ارزیابی قرار گرفت. با توجه به نتایج حاصل از مدل‌های مورد استفاده سیستم استنتاج عصبی- فازی تطبیقی (ANFIS) دارای توانایی بالایی نسبت به سیستم شبکه عصبی مصنوعی در برآورد فرسایش بوده است.

بهرامی و همکاران (۱۳۹۲) جهت انجام یک تحقیق، ۶۰ نمونه خاک از عمق ۳۰-۰ سانتیمتری در میان ۶ کوادرات یک متر مربعی که در طول ۶ ترانسکت ۱۰۰ متری در مراتع خرابه سنجی ارومیه مستقر شده بود، برداشت کرد. خصوصیات خاک (نیترژن، رس، سیلت، کربن آلی، اسیدیته، هدایت الکتریکی و وزن مخصوص ظاهری خاک) اندازه‌گیری کردند. نتایج نشان داد که بر

اساس معیارهای مجذور میانگین مربعات خطا و ضریب کارایی که در مدل رگرسیونی به ترتیب ۰/۱۶ و ۰/۴۱ در مدل شبکه عصبی مصنوعی به ترتیب ۰/۱۱ و ۰/۶۵ در مدل شبکه عصبی تطبیقی-فازی به ترتیب ۰/۰۶ و ۰/۷۹ می‌باشند، مدل شبکه عصبی تطبیقی فازی (ANFIS) به عنوان قدرتمندتری در پیشبینی کربن آلی ذره‌های خاک نسبت به آنالیز رگرسیون خطی چندمتغیره و شبکه عصبی مصنوعی عمل کرده است.

محمدی سلطان آباد و همکاران (۱۳۹۲) طی یک پژوهش فاکتورهای موثر در فرسایش در طی دوره آماری سال ۱۳۷۰ تا ۱۳۸۸ مورد بررسی قرار دادند. نتایج حاصل از شبکه عصبی مصنوعی با ۶ نرون در لایه میانی ۸۶ درصد است که بالاترین دقت شبیه سازی و همبستگی شبکه در این پژوهش است توانایی سیستم شبکه عصبی مصنوعی در پیش‌بینی فرسایش در دوره زمان ۵ ساله برابر با ۹۰ درصد است و توانایی سیستم استنتاج عصبی - فازی تطبیقی در مدل‌سازی و پیش‌بینی با اطمینان ۹۲/۹ درصد مورد ارزیابی قرار دادند. با توجه به نتایج حاصل از مدل‌های مورد استفاده سیستم استنتاج عصبی - فازی تطبیقی دارای توانایی بالای نسبت به سیستم شبکه عصبی مصنوعی در برآورد فرسایش است.





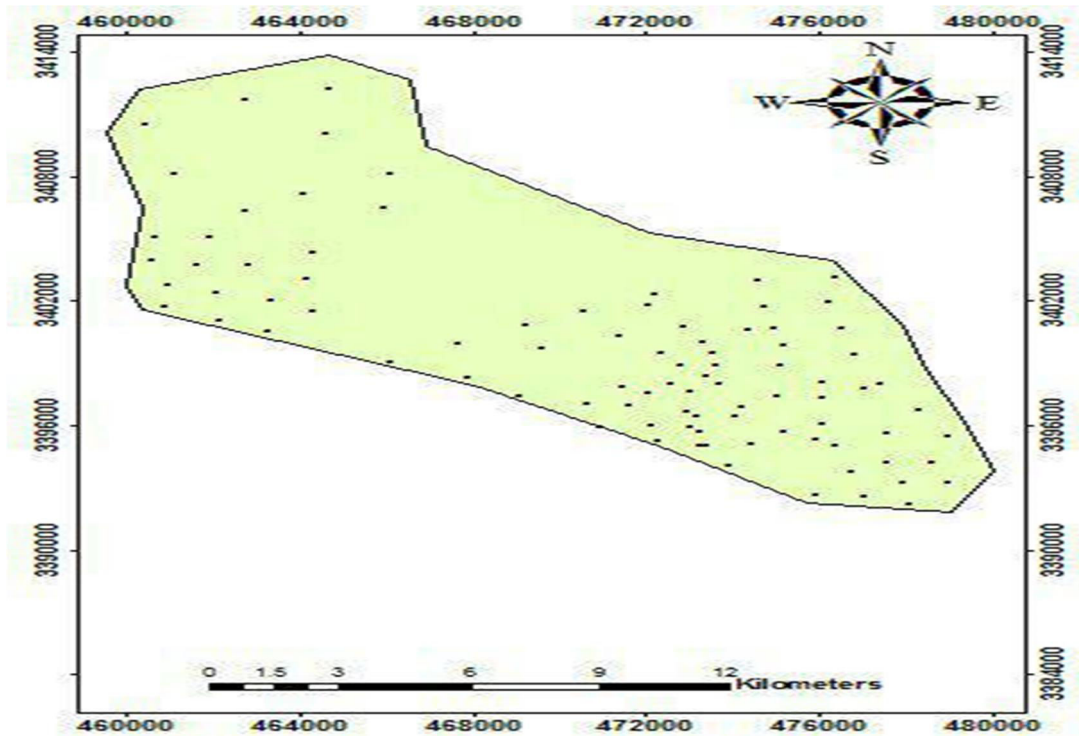
# فصل سوم

## مواد و روش ها

### ۱-۳ موقعیت جغرافیایی منطقه

مطالعه مورد نظر در شهرستان چرام و دهدشت (شکل ۱-۳) در بخش مرکزی استان

کهگیلویه و بویر احمد و با مساحت شهرستان دهدشت  $۳/۲$  کیلومتر مربع و شهرستان چرام  $۲/۸$  کیلومتر مربع می‌باشد (موسوی‌نژاد، ۱۳۸۵).



شکل ۱-۳: موقعیت مورد مطالعه در شهرستان‌های چرام و دهدشت

### ۲-۳ وضع موجود کشاورزی و پوشش طبیعی

استان کهگیلویه و بویر احمد یکی از قطب‌های مهم کشاورزی کشور است. از جمله فعالیت‌های مورد تاکید بخش کشاورزی در شهرستان دهدشت و چرام می‌توان به کشت برنج، گندم، سیفی جات، حبوبات، مرکبات، گردو، گیاهان دارویی و همچنین دامداری و پرورش شیلات اشاره کرد. از جمله پوشش طبیعی موجود در شهرستان‌های مورد مطالعه می‌توان به درخت بلوط، بنه، کیکم، بادام و زبان گنجشک و ... اشاره کرد و همچنین گیاهانی چون کنگر، بیلهر، جاشیر، چویل، آویشن، پونه و غیره اشاره کرد.

### ۳-۳ شرایط توپوگرافی

شهرستان چرام و دهدشت در امتداد رشته کوه‌های زاگرس قرار دارد و منطقه‌ای کوهستانی محسوب می‌شود.

### ۴-۳ هواشناسی منطقه‌ای

شناخت اقلیم و رژیم آب و هوایی یک منطقه و عوامل موثر بر آن نظیر درجه حرارت، بارندگی و تبخیر در برنامه‌ریزی‌های منطقه‌ای به منظور تولیدات کشاورزی و دامی و مدیریت اراضی ضروری است. جهت بررسی پارامترهای هواشناسی از آمار ایستگاه استان کهگیلویه و بویر احمد استفاده شده است. میانگین بارندگی سالانه چرام و دهدشت به ترتیب ۲۹۹ و ۳۱۴ میلیمتر و متوسط دمای روزانه شهرستان چرام و دهدشت به ترتیب ۲۱/۷ و ۲۱/۴ درجه سانتیگراد می‌باشد.

### ۵-۳ برداشت و آماده‌سازی نمونه‌های خاک

پژوهش مذکور در سال ۱۳۹۵ در اراضی کشاورزی شهرستان چرام و دهدشت در استان کهگیلویه و بویر احمد انجام داده شد. به این صورت که از تعداد ۹۰ نقطه به طور تصادفی به کمک مته از عمق ۰-۳۰ سانتی‌متری نمونه‌گیری به عمل آمد. نمونه‌ها پس از اینکه به آزمایشگاه منتقل گردیدند و به مدت ۴۸ ساعت در هوای آزاد خشک گردیده و سپس از الک ۲ میلیمتری گذرانده و آماده تجزیه شیمیایی و فیزیکی شدند. شکل ۳-۱، مختصات نقاط پروفیل‌های حفاری شده را نشان می‌دهد.

### ۶-۳ تجزیه شیمیایی و فیزیکی خاک

برای اندازه‌گیری مواد آلی موجود در این پژوهش از روش واکلی و بلاک (۱۹۳۴) استفاده گردید.

برای تعیین بافت خاک از روش هیدرومتری استفاده گردید.

برای تعیین آهک خاک از روش تیتراسیون برگشتی استفاده شد (احیائی و بهبهانی‌زاده، ۱۳۷۲).

رسانایی الکتریکی در عصاره ۱:۲/۵ خاک به آب به وسیله دستگاه هدایت سنج KCL اندازه‌گیری شد. با توجه به دمای عصاره‌ها در آزمایشگاه و مشخص کردن هدایت الکتریکی محلول استاندارد (۰/۱ نرمال) و دمای آن در محیط، هدایت الکتریکی نمونه‌ها در دما ۲۵ درجه سانتیگراد محاسبه گردید. pH خاک در سوسپانسیون ۱:۲/۵ خاک به آب با استفاده از الکتروود شیمیایی متصل به pH متر برای هر خاک اندازه‌گیری شد.

### ۳-۶-۱ آهن و روی قابل جذب خاک

آهن و روی قابل جذب در خاک با عصاره‌گیر DTPA استخراج و با دستگاه جذب اتمی قرائت شد. به این طریق که مقدار ۵ گرم خاک را در داخل یک ارلن ریخته و ۱۰ سی سی محلول عصاره‌گیر DTPA (دی اتیلن تری آمین پنتا استیک اسید) با غلظت ۰/۰۰۵ مول به آن اضافه گردید. سوسپانسیون حاصل را به مدت نیم ساعت شیک نموده و توسط کاغذ صافی عصاره زلالی از آن به دست آورده شد. پس از تنظیم دستگاه و کالیبراسیون استانداردها، میزان جذب را قرائت و غلظت آهن و روی تعیین گردید.

### ۳-۷ هوش مصنوعی


هوش مصنوعی عموماً به عنوان زیرشاخه‌ای از علوم کامپیوتر محسوب شده و ارتباط تنگاتنگی با عصب‌شناسی، علوم‌شناختی، روانشناسی شناختی، منطق ریاضی و مهندسی است. مغز مصنوعی، مغز رباتی است که یاد می‌گیرد و رفتاری شبیه مغز انسان از خود نشان می‌دهد با این تفاوت که به صورت الکترونیکی ساخته شده نه بیولوژیکی.

### ۳-۸ شبکه عصبی مصنوعی

شبکه عصبی مصنوعی به یه زبان ساده‌تر شبکه‌های عصبی سیستم‌ها، روش‌های محاسباتی نوینی هستند برای یادگیری ماشینی، نمایش دانش و پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده. ایده این گونه شبکه‌ها الهام گرفته از شیوه کارکرد سیستم عصبی زیستی، برای پردازش

داده‌ها، و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. عنصر کلیدی این ایده ایجاد ساختارهای جدیدی برای سامانه پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده بهم پیوسته با نام نورون تشکیل شده که برای حل این مسئله با هم هماهنگ عمل می‌کند. با استفاده از دانش برنامه‌نویسی رایانه می‌توان ساختار داده‌ای طراحی کرد که همانند یک نورون عمل نماید. سپس با ایجاد شبکه‌ای از نورون‌های مهم بهم پیوسته ایجاد یک الگوریتم آموزشی برای شبکه و اعمال این الگوریتم به شبکه آن را آموزش داد. در حالت کلی یک شبکه عصبی زیستی از مجموع یا مجموعه‌ای از نورون‌های به صورت فیزیکی به هم متصل یا از لحاظ عملکردی به هم وابسته تشکیل شده است. هر نورون می‌تواند به تعداد بسیار زیادی از نورون‌ها وصل باشد و تعداد کل نورون‌ها و اتصالات بین آن‌ها می‌تواند بسیار زیاد باشد. اتصالات که به آن‌ها سیناپس گفته می‌شود و معمولاً از آکسون‌ها و دندریت‌ها تشکیل شده‌اند. هوش مصنوعی و مدلسازی شناختی سعی بر این دارند که بعضی از خصوصیات شبکه‌های عصبی را شبیه‌سازی کنند.

به بیان دیگر شبکه‌های عصبی مصنوعی، در واقع نوعی سیستم پردازش اطلاعات هستند که از تعمیم یافتن مدل‌های ریاضی شبکه‌های عصبی انسان بر مبنای فرضیات زیر توسعه یافته‌اند که در (شکل ۲-۳) مدل ریاضی یک نرون نمایش داده شده است:

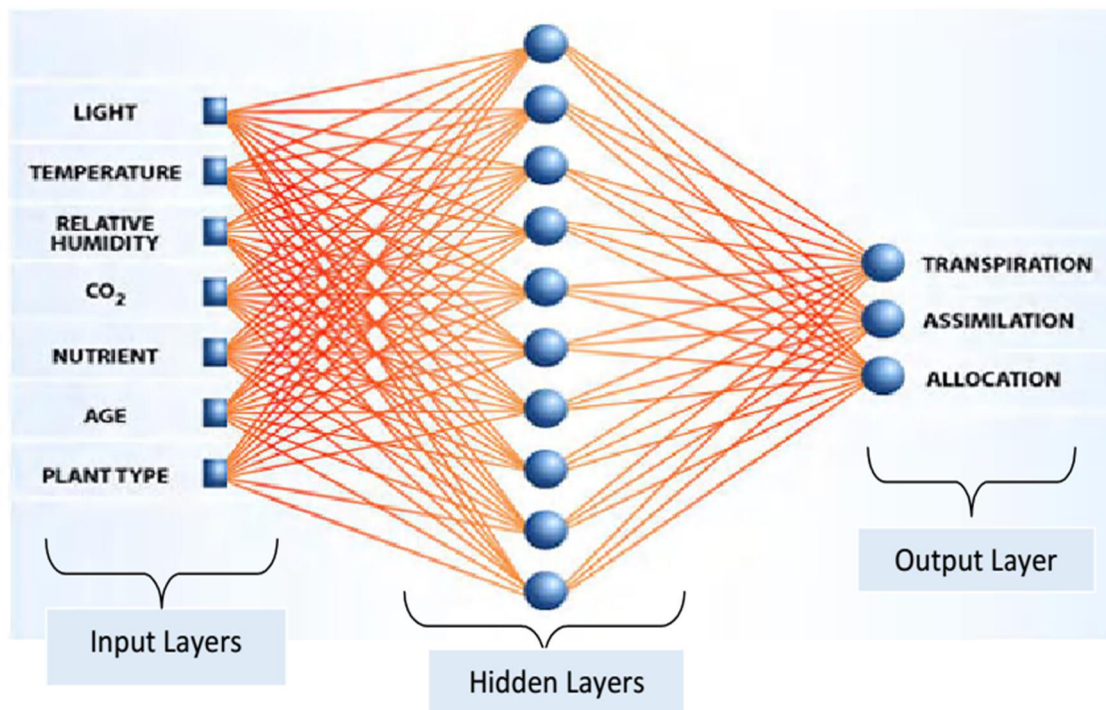


شکل ۲-۳: مدل ریاضی یک نرون

این مدل ریاضی تعریف شده که مشابه دستگاه عصبی مغز کار می‌کند و ساختار یک شبکه عصبی مصنوعی را تشکیل می‌دهد. پس یک شبکه عصبی تشکیل شده از چندین نرون عصبی است که به هنگام نیاز فعال شده و محاسبات روی آن انجام می‌گیرد. به عبارت دیگر این نرون‌ها تشکیل شده از گره‌ها و پاره خط‌های جهت داری هستند که فرآیند حل مسئله در مسیر آنها صورت می‌گیرد. گره‌هایی که در لایه ورودی هستند نرون‌هایی هستند که هیچ عملیاتی بر روی آنها صورت نمی‌گیرد و در محاسبه تعداد لایه‌ها نیز قرار نمی‌گیرند. گره‌های لایه خروجی نرون‌های پاسخ دهنده هستند که پاسخ حل مسئله در آنها نمایان می‌شود. بین نرون‌های ورودی و خروجی نیز نرون‌های پنهان قرار دارند. برای حل یک مسئله با چندین ورودی و خروجی از یک نرون به تنهایی نمی‌توان استفاده کرد. در این حال باید از چندین نرون به صورت موازی بهره جست که بتوانند بردارهای ورودی را همزمان پردازش کنند و به بردار خروجی لایه آخر منتقل کنند. درون هر نرون یک وزن به خصوصی است که با اعمال آن به مقادیر ورودی به نرون روی آنان تاثیر گذاشته و بردارهای وزن‌دار را به توابع تحریک هدایت می‌کنند. ممکن است نیاز باشد یک بردار علاوه بر آن که وزن آن تغییر کند در فضای برداری جابجا شود که این عمل با اضافه کردن یک بایاس به ماتریس وزن‌دار صورت می‌گیرد. حال مقادیر وزن‌دار به توابع تحریک برده می‌شوند، تابع تحریک بر اساس نیاز خاص حل مسئله انتخاب می‌شود که در عمل تعداد محدودی از این توابع مورد استفاده قرار می‌گیرند. سپس تابع خروجی مقدار اصلی را به خود می‌گیرد و با توجه به اینکه آیا جواب مناسب بدست آمده است یا خیر این مقادیر با بردار هدف مقایسه می‌شوند و در صورت اختلاف با بردار هدف به عقب برگشت داده می‌شوند تا وزن‌های مناسب‌تری برای آن بردارها انتخاب گردد.

در این تحقیق از بین گونه‌های مختلف شبکه عصبی، از شبکه عصبی پرسپترون چند لایه، به دلیل توانایی بالای آن برای دسته‌بندی و کلاس بندی و یافتن نگاشته‌های نامعلوم و کارایی بالای آن استفاده شده است. (رشادصدقی و محمودی، ۱۳۹۶).

شبکه عصبی پرسپترون چند لایه، از چند لایه تشکیل شده است (شکل ۳-۳). لایه ورودی، خروجی و لایه یا لایه‌های مخفی که خروجی لایه اول، بردار ورودی لایه دوم به حساب می‌آید به همین ترتیب خروجی لایه دوم، بردار ورودی سوم را تشکیل می‌دهد. خروجی لایه دوم پاسخ واقعی شبکه را نشان می‌دهند. نرونهای موجود در لایه بالادست به نرونهای موجود در لایه پائین دست ارتباط دارند. نقش هر نرون محاسبه مجموع وزن داده شده پترون ورودی (Net) سپس گذراندن این مجموع از یک تابع به نام تابع انتقال می‌باشد. تابع انتقال میتواند یک تابع خطی یا غیر خطی باشد. دو نوع از توابع مرسوم در شبکه پرسپترون چند لایه تابع سیگموئید و تانژانت سیگموئید می‌باشد. نحوه عمل پرسپترون چند لایه بدین صورت است که الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد. مقایسه خروجی واقعی و خروجی مطلوب، باعث می‌شود که ضریب وزنی شبکه تغییر یابد به طوریکه در دفعات بعد خروجی درست‌تری حاصل می‌شود. قاعده فراگیری میزان کردن، ضرایب وزنی شبکه را بیان می‌کند (نیتو و همکاران، ۲۰۱۷).



شکل ۳-۳ اجزای تشکیل دهنده یک پرسپترون چندلایه

### ۳-۹ ساختار سیستم استنتاج تطبیقی عصبی فازی (ANFIS)

برای بسیاری از کاربردهای سیستم‌های دینامیکی و غیرخطی، تئوری یا توابع خاصی ارائه نشده است که با دادن ورودی به آن، خروجی به دست آید. اما در عین حال، مدل‌های غیرتئوریک انعطاف‌پذیری تحت عنوان مدل‌های محاسبات نرم (Soft Computing Models)، جهت سیستم‌های غیرخطی ارائه گردیده است (کیا و همکاران، ۱۳۹۴). سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) شامل شبکه‌های چند لایه‌ای می‌باشند و از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیر خطی بین فضای ورودی و خروجی استفاده می‌کنند (شکل ۳-۴). این سیستم با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی به قدرت عددی یک شبکه عصبی، موقعیت‌های بسیاری را در مدل‌سازی و کنترل سیستم‌های پیچیده داشته است. سیستم ANFIS در ابتدا توسط جانگ (۱۹۹۳) معرفی گردید و از آن پس به عنوان یکی از ابزارهای تقریب ساز توابع حقیقی پیوسته (با هر مقدار دلخواه درجه دقت) در سطح جهانی مورد استفاده قرار گرفت (نصیری آفند و همکاران، ۲۰۱۷).

برای سادگی کار فرض می‌کنیم که سیستم فازی ما دو ورودی  $x$  و  $y$  دارد و خروجی آن  $Z$

است. حال اگر قوانین به صورت زیر باشند:

*Rule1: If  $x$  is  $A_1$  and  $y$  is  $B_1$ , then  $f_1 = p_1x + q_1y + r_1$*

*Rule2: If  $x$  is  $A_2$  and  $y$  is  $B_2$ , then  $f_2 = p_2x + q_2y + r_2$*

و اگر برای غیرفازی سازی (تبدیل خروجی نهایی سیستم به یک عدد کلاسیک) از روش میانگین

مراکز استفاده کنیم خروجی به صورت زیر خواهد بود:

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad \text{st} \quad \bar{w}_1 = \frac{w_1}{w_1 + w_2}, \quad \bar{w}_2 = \frac{w_2}{w_1 + w_2}$$

ساختار معادل ANFIS که از پنج لایه تشکیل شده است به صورت زیر خواهد بود (شکل ۳-۵):



لایه اول (گره‌های ورودی): در این لایه درجه عضویت گره‌های ورودی به بازه‌های مختلف فازی با

استفاده از تابع عضویت، مشخص می‌گردد

$$O_{1,i} = \mu A_i(x), \quad \text{for } i = 1,2$$

$$O_{1,i} = \mu B_i(y), \quad \text{for } i = 3,4$$

لایه دوم (گره‌های قاعده): هر گره در این لایه درجه فعالیت یک قانون را محاسبه می‌کند:

$$O_{2,i} = w_i = \mu A_i(x) \times \mu B_i(y), \quad i = 1,2$$

لایه سوم: خروجی این لایه نرمالیزه شده لایه قبلی است:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2$$

لایه چهارم: (گره‌های نتیجه) در این لایه خروجی هر گره برابر است با:

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (P_i x + q_i y + r_i)$$

لایه پنجم: (گره‌های خروجی) در این لایه هر گره مقدار خروجی نهایی را به صورت زیر محاسبه

می‌نماید (تعداد گره‌ها برابر تعداد خروجی‌هاست)

$$\text{Overall output} = O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

آموزش این سیستم‌ها به این مفهوم است که با استفاده از داده‌های آموزشی پارامترهای


غیرخطی مربوط به توابع عضویت فازی در لایه اول و پارامترهای خطی لایه چهارم طوری تعیین

شوند که به ازای ورودی دلخواه، خروجی مطلوب حاصل شود. روش آموزش هیبرید (Hybrid

learning) از مهمترین روش‌های آموزش سیستم‌های استنتاج فازی برپایه شبکه عصبی تطبیقی

می‌باشد. در این روش جهت آموزش در لایه اول از روش پس انتشار خطا (Back propagation) و

در لایه چهارم سیستم از روش تخمین کمترین مربعات استفاده می‌شود (Jang and Sun, 1997).



شکل ۳-۴- ساختار مدل انفیس

# فصل ہمارم

## تسایج و بحث

این فصل شامل نتایج حاصل از مدل‌سازی عناصر دیریافت خاک شامل آهن و روی خاک توسط پارامترهای ورودی مشابه برای هر دو مدل شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی فازی است. به دلیل مقایسه دو مدل مذکور پارامترهای ورودی مشابه در نظر گرفته شده است.

#### ۱-۴ همبستگی بین پارامترهای اندازه‌گیری شده

نتایج حاصل از همبستگی میان پارامترهای دیریافت خاک شامل غلظت قابل عصاره‌گیری با DTPA عناصر آهن و روی خاک با پارامترهای زودیافت خاک از جمله درصد رس، هدایت الکتریکی، اسیدیته گل اشباع، میزان ماده آلی و آهک خاک بدست آمد (جدول ۱-۴).

جدول ۱-۴: همبستگی میان پارامترهای زودیافت خاک با غلظت آهن و روی خاک قابل عصاره‌گیری با DTPA خاک

ماده آلی	رس	آهک	اسیدیته	هدایت الکتریکی	
۰/۳۶۱**	۰/۳۳۵**	۰/۰۳۶	-۰/۲۴	-۰/۱۴۳	آهن قابل جذب
۰/۱۷۴	۰/۱۸۶	-۰/۰۵۶	-۰/۳۴۹**	۰/۲۹۳**	روی قابل جذب

\*\*\* و \*\* و ns به ترتیب به معنی معنی‌دار بودن نتایج در سطح ۵ درصد، ۱ درصد و عدم وجود اثر معنی‌دار می‌باشد

بیشترین میزان همبستگی غلظت عنصر آهن با مقدار ماده آلی و درصد رس خاک بوده است. به گونه‌ای که در هر دو مورد همبستگی مثبت و معنی‌داری در سطح یک درصد بین عنصر آهن و دو فاکتور یاد شده مشاهده شد.

همبستگی مثبت و معنی‌دار آهن قابل عصاره‌گیری با DTPA با درصد رس و ماده آلی قابل انتظار بود، چرا که منبع اصلی آهن در اکسیدهای آهن بی‌شکل است که اغلب همراه با مواد آلی و سیلیکات‌های لایه‌ای می‌باشد. اکسیدهای آهن بی‌شکل واکنش‌پذیری سطحی بالایی دارند و از این رو می‌توانند در تعادل با آهن محلول و تبادلی قرار گیرند (سامر و همکاران، ۲۰۱۱).

آل-مصطفی و همکاران (۲۰۰۱) در خاک‌های عربستان همبستگی مثبت معنی‌داری بین مواد آلی و رس با آهن عصاره‌گیری شده توسط DTPA و همبستگی منفی معنی‌داری با pH خاک را

گزارش کردند. ویجای کومار و همکاران (۲۰۱۱) و مه‌شابد و پاتل (۲۰۱۲) در خاک‌های هند گزارش کردند که آهن عصاره‌گیری شده توسط DTPA همبستگی منفی با pH و درصد  $\text{CaCO}_3$  و همچنین همبستگی مثبتی با درصد ماده آلی را در خاک مشاهده کردند.

همچنین نتایج همبستگی بین غلظت عنصر روی قابل عصاره‌گیری با DTPA با سایر فاکتورهای مورد اندازه‌گیری نشان داد که بیشترین میزان همبستگی بین اسیدیت و هدایت الکتریکی با عنصر روی در خاک وجود داشته است. همبستگی منفی بین غلظت روی و اسیدیت در خاک و همبستگی مثبت بین غلظت این عنصر با هدایت الکتریکی خاک در سطح یک درصد معنی‌دار بوده است (جدول ۴-۱).

روی یک عنصر غذایی کم مصرف ضروری است که اکثر گیاهان عالی جهت رشد نرمال و توسعه کمی و کیفی، به آن نیاز دارند. در بین عناصر غذایی کم مصرف، کمبود روی در اکثر گیاهان زراعی یکی از گسترده‌ترین و پرتکرارترین کمبودها است (شهبازی و بشارتی، ۲۰۱۳). حتی اگر مقدار کل روی در خاک بالا باشد، کمبود آن محتمل است، چون زیست‌فراهمی روی در خاک به خصوصیات شیمیایی خاک وابسته است. در پی افزایش اسیدیت خاک از ۵ به ۸، غلظت عنصر روی در محلول خاک از  $10^{-4}$  ( $6/5 \mu\text{g/g}$ ) به  $10^{-10}$  ( $0/007 \mu\text{g/g}$ ) کاهش می‌یابد (شهبازی و بشارتی، ۲۰۱۳). اسیدیت در خاک یکی از مهمترین عواملی است که سبب کاهش زیست‌فراهمی روی در خاک می‌شود. افزودن ماده آلی به خاک می‌تواند شرایط بیوشیمیایی خاک را تغییر داده و سبب افزایش زیست‌فراهمی و آزاد شدن روی از شکل‌های پایدار شوند (بوستانی و همکاران، ۲۰۱۶).

نتایج این پژوهش با نتایج پژوهش‌های دیگر در همبستگی منفی بین غلظت عنصر روی قابل عصاره‌گیری با DTPA با اسیدیت خاک مطابقت دارد. بوستانی و همکاران (۲۰۱۷) با افزودن دو درصد وزنی کود گاوی و کاه و کلش گندم در یک خاک آهکی پس از کشت ذرت مشاهده کردند که شکل محلول و تبدالی روی به طور معناداری با کاهش اسیدیت افزایش یافت است. سابرامانیا و

همکاران (۲۰۰۹) بیان کردند که فعالیت میکروبی فشرده و فعالیت آنزیم‌های فسفاتاز در خاک‌های تیمار شده با قارچ سبب کاهش pH ریزوسفر شده و می‌تواند سبب آزادسازی روی از شکل‌های کریستالی باشد. قشلاقی و همکاران (۲۰۰۹) طی یک پژوهش به این نتیجه رسیدن که غلظت عناصر نیکل، کرم، منگنز و روی قابل استخراج با DTPA همبستگی مثبتی با هدایت الکتریکی خاک را دارا می‌باشد. نتایج پژوهش حاضر نیز به همبستگی مثبت هدایت الکتریکی و همبستگی منفی اسیدیته در غلظت روی قابل استخراج با DTPA را در خاک اشاره میکند.

#### ۲-۴ پارامترهای آماری و ویژگی‌های مورد مطالعه

بررسی پارامترهای آماری برای ماده آلی خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار ماده آلی خاک به ترتیب ۰/۱۳ و ۵/۴۹ درصد بوده است. همچنین میانگین مقدار ماده آلی خاک در منطقه مطالعاتی ۱/۸ درصد بوده است (جدول ۲-۴).

جدول ۲-۴: پارامترهای آماری فاکتورهای مورد مطالعه

واحد	حداقل	حداکثر	دامنه	میانگین	واریانس	چولگی	کشیدگی	آزمون کولموگروف اسمیرنوف
ماده آلی درصد	۰/۱۳	۵/۴۹	۵/۳۶	۱/۹	۰/۹۹۴	۰/۹۴۵	۱/۴۳	۰/۰۷۵
pH	۷/۰۸	۸/۹۴	۱/۸۶	۸/۱۸	۰/۱۱۱	۰/۹۶۴	-۰/۴۳۷	۰/۰۲۸
رس درصد	۱/۲۸	۵۷/۲۴	۵۵/۹۶	۳۲/۲۲	۱۰۷/۳۳۴	۰/۴۶۹	-۰/۴۲۹	۰/۲
آهک درصد	۱۴	۸۰	۶۶	۵۱	۲۶۳/۰۰۹	۰/۳۵۷	۰/۱۸۴	۰/۰۹۶
هدایت الکتریکی ds/m	۰/۱۷	۲/۵	۲/۳۳	۰/۶	۰/۲۱۲	۵/۰۰۴	۲/۱۵۴	-
آهن mg/kg	۰/۳	۰/۷۸	۱/۰۸	۰/۵۱	۰/۰۳۵	۱/۰۹۱	۰/۲۸۳	۰/۰۷۵
روی mg/kg	۰/۶۲	۲/۴۱	۱/۷۹	۱/۴۲	۰/۱۵۱	-۰/۰۶۶	۰/۲۹	۰/۲

در بین کاربری‌های مورد مطالعه در این پژوهش، کاربری باغ مرکبات به واسطه پوشش درختی مطلوب، توان حفظ رطوبت خاک و پویایی اکوسیستم، بیشترین میزان کربن آلی ورودی به خاک را نسبت به کاربری زراعی نشان می‌دهد. از سوی دیگر، به دلیل وجود ساختمان مناسب خاک و

مصون ماندن درختان از چرای دام، قابلیت فرسایش پذیری کمتری نسبت به سایر مناطق داشته و در نتیجه نسبت کربن ورودی به کربن خروجی افزایش را نشان می‌دهد. به دلیل برداشت بخش عمده پوشش گیاهی در اراضی با کاربری زراعی و به دنبال آن کاهش بازگشت بقایای گیاهی به خاک، کربن ورودی به اکوسیستم، کم تر از کربن خروجی مشاهده شد. در این بررسی بین کاربری باغ و اراضی زراعی، باغ از درصد کربن آلی بیشتری برخوردار بود. مهمترین عاملی که در تسریع کاهش ماده آلی در خاک با کاربری زراعی تأثیر میگذارد، کشت و کار است که موجب افزایش تجزیه مواد آلی خاک طی عملیات شخم می‌شود و عاملی برای کاهش کربن آلی خاک به شمار می‌آید.

این نتایج همچنین با نتایج مایا و همکاران (۲۰۱۰) مطابقت دارد. آن‌ها کاهش مواد آلی بر اثر کشت و کار را به دو دلیل به هم خوردن خاک سطحی و در نتیجه تسریع تجزیه بیولوژیکی مواد آلی، تشدید فرسایش خاک و به دنبال آن هدررفت مواد آلی همراه با رواناب گزارش نمودند. کیزیلکایا و دنگیز (۲۰۱۰) طی یک پژوهش به این نتیجه رسیدن که خاکورزی فشرده و حذف زیست توده گیاه از مزارع و یا اکوسیستم‌های طبیعی مانند مراتع ممکن است باعث کاهش غلظت ماده آلی خاک که معضلات زیادی را به دنبال خواهد داشت، گردد.

بررسی پارامترهای آماری برای pH خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار pH خاک به ترتیب ۷/۰۸ و ۸/۹۴ درصد بوده است. همچنین میانگین pH خاک در منطقه مطالعاتی ۸/۱۸ بوده است (جدول ۴-۲).

از آنجاییکه کربنات کلسیم یکی از مهمترین عوامل کنترل کننده pH خاک به خصوص در

خاک‌های مناطق خشک و نیمه خشک با مقدار قابل ملاحظه‌ای آهک و همچنین در خاک‌های

تشکیل یافته از مواد مادری آهکی است، اگر تفاوت در درصد آهک در کاربری‌های مختلف را مد نظر

قرار دهیم، مشاهده میشود که این تغییرات با هم متناسب هستند. به طوریکه بیشترین pH و

بیشترین درصد آهک در اراضی با کاربری زراعی و کمترین pH و کمترین درصد آهک مربوط به

اراضی با کاربری باغی مشاهده شد. دلیل این تفاوت می تواند مربوط به این موضوع باشد که در کاربری باغی به دلیل تراکم بیشتر گیاه و ریشه گیاه و همچنین تنفس بیشتر ریشه گیاه در کاربری باغ با افزایش  $H^+$  همراه با آنیون های آلی یا از طریق فرایند نیتریفیکاسیون در یک سیستم باز، می توانند pH را کاهش دهند (عباسپور و همکاران، ۲۰۰۸). مواد آلی یکی دیگر از عواملی است که باعث کاهش pH در اراضی با کاربری باغ نسبت به اراضی با کاربری زراعی است چرا که کاربری باغ مرکبات به واسطه پوشش درختی مطلوب، توان حفظ رطوبت خاک و پویایی اکوسیستم، بیشترین میزان کربن آلی ورودی به خاک را نسبت به کاربری زراعی نشان می دهد. کاشی و همکاران (۲۰۱۲) نیز نشان داد که کربنات کلسیم موجود در خاک با pH خاک رابطه مستقیم دارد که با نتایج این پژوهش همسو می باشد.

بررسی پارامترهای آماری برای درصد رس خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار درصد رس خاک به ترتیب ۱/۲۸ و ۵۷/۲۴ درصد بوده است. همچنین میانگین مقدار رس خاک در منطقه مطالعاتی ۳۲/۲ درصد بوده است (جدول ۴-۲).

نتایج این پژوهش نشان داد که اراضی با کاربری زراعی با ۵۷/۲۴ درصد دارای بیشترین و اراضی با کاربری باغ با ۱/۲۸ درصد دارای کمترین مقدار درصد رس بوده است.

بررسی پارامترهای آماری برای درصد آهک خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار درصد آهک خاک به ترتیب ۱۴ و ۸۰ درصد بوده است. همچنین میانگین مقدار آهک خاک در منطقه مطالعاتی ۵۱ درصد بوده است (جدول ۴-۲).

نتایج این پژوهش نشان داد که اراضی با کاربری زراعی با ۸۰ درصد دارای بیشترین و اراضی با کاربری باغی با ۱۴ درصد دارای کمترین مقدار آهک بود. اگر تفاوت در درصد آهک در کاربریهای مختلف را مد نظر قرار دهیم، مشاهده می شود که این تغییرات با هم متناسب هستند. به طوریکه بیشترین pH و بیشترین درصد آهک در کاربری زراعی و کمترین pH و کمترین درصد آهک مربوط



به کاربری باغ بوده است. دلیل این تفاوت می‌تواند مربوط به این موضوع باشد که در کاربری زراعی به دلیل تراکم کمتر گیاهان و مواد آلی توانایی بهبود خصوصیات شیمیایی خاک را کمتر دارند. بدین صورت که ماده آلی می‌تواند در تنظیم PH خاک اثر داشته باشد و در نتیجه در کاهش آهک خاک موثر باشد.

بررسی پارامترهای آماری برای هدایت الکتریکی خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار هدایت الکتریکی خاک به ترتیب ۰/۱۷ و ۲/۵ درصد بوده است. همچنین میانگین هدایت الکتریکی خاک در منطقه مطالعاتی ۰/۶ بوده است (جدول ۴-۲).

قابلیت هدایت الکتریکی در کاربری باغ دارای بیشترین مقدار و در اراضی با کاربری زراعی کمترین مقدار بوده است. این امر می‌تواند به علت تاج پوشش بسته درختان و میزان لاشبرگ بیشتر باشد که این خود می‌تواند دلیل بر افزایش میزان هدایت الکتریکی خاک باشد. تغییر کاربری مراتع به باغ و استفاده بیش از حد از کود برای افزایش عملکرد محصول دلیلی بر افزایش هدایت الکتریکی در این اراضی نسبت به اراضی با کاربری کشت غلات و حبوبات می‌باشد.

نیک نام قرماخر و مارامائی (۲۰۱۱) نیز در مطالعه اثرات تغییر کاربری اراضی بر خصوصیات خاک حوضه آبخیز کچیک به این نتیجه رسیدند که قابلیت هدایت الکتریکی خاک زراعی در مقایسه با کاربری مرتع تفاوت معنی‌داری داشت، که دلیل این امر را افزایش کود به زمین زراعی بیان کردند. (حاج عباسی و همکاران ۲۰۰۸) نیز در مطالعه خود در خاک‌های جنوب و جنوب غربی اصفهان نشان دادند که در اراضی باغی و اعمال عملیات کشت و کار و کوددهی سبب افزایش مقدار قابلیت الکتریکی خاک در زمین‌های کشاورزی شده است که نتایج آنها با تحقیق حاضر همخوانی دارد.

بررسی پارامترهای آماری برای غلظت آهن خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار غلظت آهن خاک به ترتیب ۰/۳ و ۰/۷۸ درصد بوده است. همچنین میانگین غلظت آهن خاک در منطقه مطالعاتی ۱/۵۶ بوده است (جدول ۴-۲).

میزان عنصر آهن قابل جذب در خاک‌های کشاورزی یکی از مهمترین ویژگی‌های موثر در تولید محصولات زراعی می‌باشد. به منظور رسیدن به حداکثر تولید در کشاورزی، توجه ویژه به مدیریت این عنصر الزامی است. نتایج این پژوهش نشان داد که اراضی با کاربری باغ با ۰/۷۸ میلی‌گرم در کیلوگرم خاک دارای بیشترین و اراضی با کاربری زراعی با ۰/۳ میلی‌گرم در کیلوگرم خاک دارای کمترین میزان آهن قابل جذب مشاهده شد. آهن بیش از تمامی عناصر کم مصرف برای گیاه مورد نظر است. دانستن خصوصیات خاک، بویژه خصوصیتی که از نظر تولیدات کشاورزی و مسائل اقتصادی مهم هستند، دارای اهمیت بسیار است (فجریا، ۲۰۱۰). کلروز ناشی از کمبود آهن در خاک‌های آهکی و pH بالا بسیار شایع است. خاک‌های آهکی بیش از ۳۱ درصد سطح خشکی‌های زمین را می‌پوشانند (مارشور و مارشور، ۲۰۱۲). از آنجایی که pH خاک‌های آهکی بالاست یکی از علل شیوع کمبود آهن در خاک‌های آهکی را می‌توان همین ویژگی دانست. آهکی بودن خاک، گونه‌های حساس، غلظت بالای بیکربنات و نیترات در خاک و آب آبیاری، حلالیت شدیداً پایین آهن که عمدتاً به شکل اکسیدهای فریکاند، افزایش تراکم محصولات زراعی، کمبود مواد آلی، استفاده از ارقام با عملکرد بالا، استفاده بی‌رویه و کاهش عملکرد محصول باعث بروز علائم کمبود آهن شده است. نتایج پژوهش حاضر نیز به تأثیر مثبت آهک و pH خاک و همچنین کمبود مواد آلی بر کاهش غلظت عنصر آهن در خاک‌های با کاربری زراعی نسبت به اراضی با کاربری باغی اشاره می‌کند.

شهبازی و بشارتی (۲۰۱۳) طی یک پژوهش بر روی خاک‌های آذربایجان شرقی به این نتیجه رسیدند که در بین عناصر کم مصرف، آهن و روی می‌توانند در کشور ایران بیشترین خسارت را به محصولات کشاورزی وارد کنند، به طوری که بیش از ۴۰ درصد خاک‌های زراعی ایران کمتر از ۴/۵ میلی‌گرم بر کیلوگرم آهن قابل استفاده دارند.

بررسی پارامترهای آماری برای غلظت عنصر روی خاک در منطقه مورد مطالعه نشان داد که کمترین و بیشترین مقدار غلظت عنصر روی خاک به ترتیب ۰/۶۲ و ۲/۴۱ درصد بوده است. همچنین میانگین عنصر روی خاک در منطقه مطالعاتی ۱/۴۲ بوده است (جدول ۴-۲).

عنصر روی یکی از عناصر مهم و ضروری در فرایند رشد و نمو در گیاهان و جانوران می باشد، چرا که این عنصر در بسیاری از واکنش های آنزیمی، فرایندهای متابولیکی و همچنین واکنش های اکسایش-کاهش نقش اساسی ایفا می کند، علاوه براین، عنصر روی در ساختار بسیاری از آنزیم های دخیل در فرایند های متابولیسم نیتروژن، انتقال انرژی و سنتز پروتئین نقش اساسی دارد (حافظ و همکاران، ۲۰۱۳). نتایج این پژوهش نشان داد که اراضی با کاربری باغ با ۲/۴۱ میلی گرم در کیلوگرم خاک دارای بیشترین و اراضی با کاربری زراعی با ۰/۶۲ میلی گرم در کیلوگرم خاک دارای کمترین میزان عنصر روی بود. کمبود روی را تقریباً می توان در تمام نقاط دنیا و در تمام محصولات کشاورزی مشاهده کرد، بر همین اساس تقریباً با یک قطعیت می توان گفت کاربرد ترکیبات دارای روی در همه خاک های کشاورزی جهان تاثیرات مثبتی بر کشت خواهد داشت (حافظ و همکاران، ۲۰۱۳). به طور کلی می توان این چنین بیان داشت که، همواره بخشی از عناصر میکرو موجود در خاک ها از طریق فرایندهای تخریب و فرسایش سنگ ها و صخرها در طول زمان تامین می شود، اما باید در نظر داشت که، مقدار مجموع هر یک از این عناصر به فاکتورهای متعددی از قبیل نوع و بافت خاک، شرایط آب و هوایی، شدت فرسایش و فاکتورهای دیگری که در طول زمان تشکیل خاک مورد اهمیت هستند، مربوط می شود (کاکماک و همکاران، ۲۰۱۷). علاوه بر تمام این موارد، در مطالعه مذکور در مورد عنصر روی فاکتورهای دیگری چون اسیدیته ی بالای خاک و وجود مقادیر زیاد کربنات کلسیم، رس و فسفات در خاک های با کاربری زراعی می توان در سطح بالایی این عنصر را در خاک تثبیت نمود، به نحوی که مقداری از کل روی خاک از دسترس گیاهان خارج است و گیاه قادر به جذب آن ها نمی باشد.

نصرت پور و همکاران (۱۳۸۹) با بررسی توزیع مکانی برخی از عناصر غذایی در اراضی شهرستان مراغه با استفاده از سامانه اطلاعات جغرافیایی نشان دادند که در قسمت عمده اراضی نمونه برداری شده کمبود عناصر کم مصرف روی، منگنز، آهن، بور و مس شایع بوده و در این میان کمبود عنصر روی بیشتر از عناصر دیگر بود. از جمله مهمترین دلایل این کمبود را زیاد بودن درصد آهک و رس و قلیایی بودن خاک قلمداد کردند که این نتایج با نتایج مطالعه مذکور همخوانی دارد.

اگر آزمون گولموگروف در نرم افزار spss16 برای هر پارامتر بیش از ۰/۰۵ باشد داده‌ها نرکال است و نیازی به نرمال سازی ندارد و در صورتیکه داده‌ها نرمال نباشد لگاریتم داده‌ها را بدست می‌آوریم و آن‌ها را نرمال می‌کنیم.

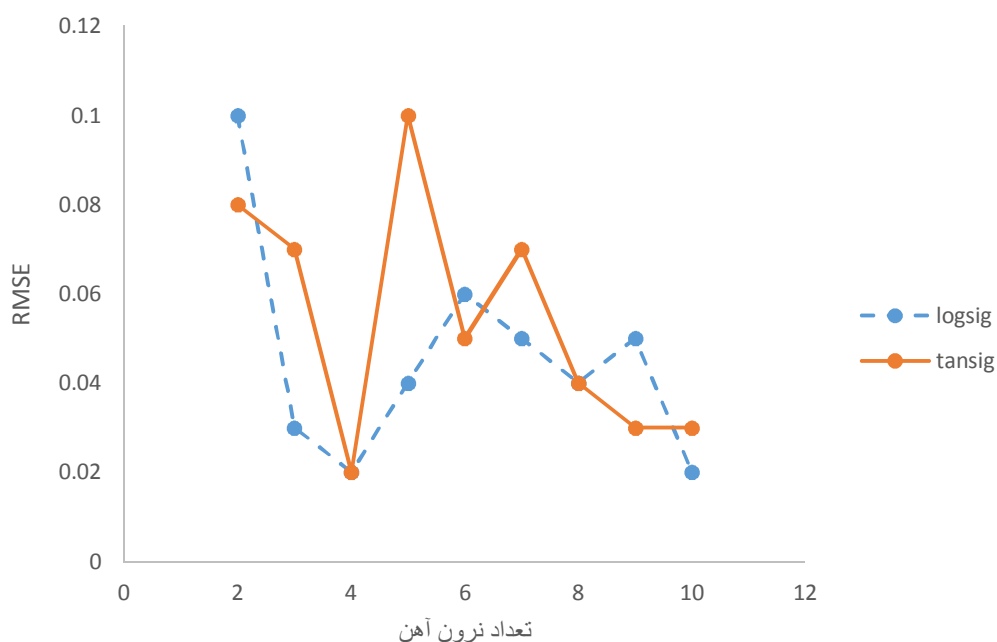
#### ۳-۴ اجرای شبکه عصبی پرسپترون (MLP) برای محاسبه عناصر آهن و روی

از آنجایی که تعداد لایه های میانی و نوع تابع انتقال در آموزش و یادگیری شبکه عصبی مصنوعی تاثیر دارد، مدل با ساختار مختلف مورد بررسی قرار گرفت. پس از تغییر در نرون‌های لایه پنهان و تکرار حین آموزش شبکه بهترین ساختار شبکه مشخص شد (جدول ۳-۴).

جدول ۳-۴: نتایج حاصل از اجرای بهترین ساختار شبکه عصبی برای پیش‌بینی آهن خاک

نوع تابع محرک لایه میانی	تعداد نرون لایه میانی	ساختار شبکه	ضریب تبیین آموزش	ضریب تبیین آزمون	خطای شبیه سازی (RMSE)	ضریب تبیین شبیه سازی
Tansig	۴	۱-۴-۵	۰/۹۹	۰/۹۳	۰/۰۲۴	۰/۹۳
Logsig	۴	۱-۴-۵	۰/۹۸	۰/۹۲	۰/۰۲۸	۰/۹۱

نتایج نشان داد که در پیش‌بینی غلظت آهن خاک بهترین ساختار شبکه برای هر دو تابع محرک لگاریتم سیگموئید و تانژانت سیگموئید به صورت ۱-۴-۵ و در نتیجه با ۴ نرون در لایه میانی بوده است (شکل ۱-۴).




شکل ۴-۱: نمودار مقدار خطا در مقابل تعداد نرون لایه میانی در پیش بینی عنصر آهن برای تابع محرک لگاریتم سیگموئید و تانژانت سیگموئید توسط مدل MLP


ضریب تبیین در مرحله آموزش و آزمون شبکه با تابع محرک تانژانت سیگموئید به ترتیب برابر با ۰/۹۹ و ۰/۹۳ بوده است. همچنین میزان خطای شبیه سازی (RMSE) برای این عنصر با تابع محرک تانژانت سیگموئید برابر ۰/۰۲۴ و ضریب تبیین برابر ۰/۹۳ بوده است. همچنین در بررسی تابع محرک لگاریتم سیگموئید در اجرای شبکه برای عنصر آهن ضریب تبیین در مرحله آموزش و آزمون شبکه به ترتیب برابر با ۰/۹۸ و ۰/۹۲ بوده است. همچنین میزان خطای شبیه سازی (RMSE) برای این عنصر با تابع محرک لگاریتم سیگموئید برابر ۰/۰۲۸ و ضریب تبیین برابر ۰/۹۱ بوده است (جدول ۳-۴). بنابراین به نظر می رسد بهترین ساختار شبکه برای پیش بینی غلظت قابل جذب آهن توسط شبکه عصبی و با پارامترهای ورودی مورد بررسی، ساختار ۱-۴-۵ با تابع محرک تانژانت سیگموئید در لایه میانی باشد.

شکل های ۲-۴ و ۳-۴ به ترتیب پراکنش داده های مشاهداتی و پیش بینی شده برای غلظت آهن در خاک توسط مدل را برای دو تابع محرک مورد مطالعه در لایه میانی نشان می دهد. همانطور

که مشخص است مدل شبکه عصبی با ساختارهای مطرح شده توانسته تا حد قابل قبولی به پیش‌بینی غلظت آهن خاک بپردازد.



شکل ۴-۲: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای غلظت روی خاک با تابع محرک تانژانت سیگموئید (مدل MLP)



شکل ۴-۳: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای غلظت آهن خاک با تابع محرک لگاریتم سیگموئید (مدل MLP)

نتایج نشان داد که در پیش‌بینی غلظت عنصر روی خاک بهترین ساختار شبکه برای دو تابع محرک لگاریتم سیگموئید و تانژانت سیگموئید به ترتیب به صورت ۵-۷-۱ و ۵-۸-۱ در نتیجه با ۷ و ۸ نرون در لایه میانی بوده است (شکل ۴-۴).

جدول ۴-۴: نتایج حاصل از اجرای بهترین ساختار شبکه عصبی برای پیش‌بینی روی خاک

نوع تابع محرک لایه میانی	تعداد نورون لایه میانی	ساختار شبکه	ضریب تبیین آموزش	ضریب تبیین آزمون	خطای شبیه‌سازی (RMSE)	ضریب تبیین شبیه‌سازی
Tansig	۸	۱-۸-۵	۰/۶۱	۰/۸۴	۰/۱۱۰۵	۰/۳۱
Logsig	۷	۱-۷-۵	۰/۶۱	۰/۶۵	۰/۱۱۱۴	۰/۳۰




شکل ۴-۴: نمودار مقدار خطا در مقابل تعداد نورون در پیش‌بینی غلظت عنصر روی خاک با دو تابع محرک لگاریتم سیگموئید و تانژانت سیگموئید در لایه میانی توسط مدل MLP

ضریب تبیین در مرحله آموزش و آزمون شبکه با تابع محرک تانژانت سیگموئید به ترتیب برابر با ۰/۶۱ و ۰/۸۴ بوده است. همچنین میزان خطای شبیه‌سازی (RMSE) برای این عنصر با تابع محرک تانژانت سیگموئید برابر ۰/۱۱۰۵ و ضریب تبیین برابر ۰/۳۱ بوده است. همچنین در بررسی


تابع محرک لگاریتم سیگموئید در اجرای شبکه برای عنصر روی ضریب تبیین در مرحله آموزش و آزمون شبکه به ترتیب برابر با ۰/۶۱ و ۰/۶۵ بوده است. همچنین میزان خطای شبیه‌سازی (RMSE) برای این عنصر با تابع محرک لگاریتم سیگموئید برابر ۰/۱۱۱۴ و ضریب تبیین برابر ۰/۳۰ بوده است (جدول ۴-۴). بنابراین به نظر می‌رسد بهترین ساختار شبکه برای پیش‌بینی غلظت قابل جذب عنصر روی توسط شبکه عصبی و با پارامترهای ورودی مورد بررسی، ساختار ۱-۸-۵ با تابع محرک و تانژانت سیگموئید در لایه میانی باشد.

شکل ۴-۵ و ۴-۶ به ترتیب پراکنش داده‌های مشاهداتی و پیش‌بینی شده مربوط به عنصر روی توسط مدل را برای دو تابع محرک میانی مورد مطالعه نشان می‌دهد. همانطور که مشخص است مدل شبکه عصبی با ساختارهای مطرح شده نتوانسته تا حد قابل قبولی به پیش‌بینی غلظت عنصر روی خاک بپردازد و مقدار خطای شبیه‌سازی زیاد و ضریب تبیین کم بر این موضوع تأکید دارد.



شکل ۴-۵: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی عنصر روی برای تابع محرک تانژانت سیگموئید (مدل MLP)





شکل ۴-۶: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی عنصر روی برای تابع محرک لگاریتم سیگموئید (مدل MLP)

کارایی شبکه‌های عصبی مصنوعی در برآورد ویژگی‌های مختلف خاک در پژوهش‌های مختلفی مورد بررسی قرار گرفته است. پهلوان راد و همکاران (۱۳۹۵) به کمک شبکه عصبی مصنوعی به پیش‌بینی شوری و رس خاک پرداخته و نشان دادند شبکه‌های عصبی کارایی خوبی در این زمینه دارند. ژائو و همکاران (۲۰۰۹) با استفاده از مدل شبکه عصبی مصنوعی مقادیر شن و رس خاک را بر اساس پارامترهای به دست آمده از نقشه ارتفاعی برآورد کرده و مشاهده کردند که دقت نسبی برای مقدار رس ۸۸ درصد و برای شن ۸۱ درصد بود.

#### ۴-۴ اجرای مدل سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی خاک


اجرای مدل سیستم استنتاج تطبیقی عصبی فازی نیز توسط نرم‌افزار MATLAB 2015 انجام گردید و برای اینکه بتوان برتری دو مدل شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی فازی را برای پیش‌بینی عناصر دیریافت خاک تعیین کرد، پارامترهای ورودی به هر دو نوع مدل یکسان در نظر گرفته شد. در سیستم استنتاج فازی عصبی تطبیقی، ابتدا ساختار مدل با

مشخصه‌های مشخص، که متناسب با ورودی‌ها، درجه عضویت وقوانین و توابع درجه عضویت خروجی است، انتخاب می‌شود. در مدل انفیس تمامی توابع عضویت  $\text{trimf}$ ,  $\text{trapmf}$ ,  $\text{gbellmf}$ ,  $\text{gaussmf}$   $\text{gaussmf2}$ ,  $\text{pimf}$ ,  $\text{dsigmf}$ ,  $\text{psigmf}$  سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی خاک در جدول ۴-۵ نشان داده شده است. نتایج حاصل برای پیش‌بینی عنصر آهن نشان می‌دهد که مدل ANFIS با تابع عضویت گوسین و با تعداد تابع عضویت ۳ بهترین ساختار را در پیش‌بینی غلظت عنصر آهن خاک ایجاد نموده است. میزان تابع خطا برای مرحله آموزش و آزمون به ترتیب ۰/۰۰۹۹ و ۰/۰۰۲۶ بوده است. همچنین میزان خطا در شبیه‌سازی غلظت عنصر آهن ۰/۰۰۹۴ و میزان ضریب تبیین ۰/۹۹ برای این عنصر بوده است.

جدول ۴-۵ نتایج حاصل از اجرای بهترین ساختار شبکه ANFIS برای پیش‌بینی آهن خاک

خروجی مدل	نوع تابع عضویت	تعداد توابع عضویت	تکرار	خطای آموزش	خطای آزمون	خطای شبیه‌سازی (RMSE)	ضریب تبیین شبیه‌سازی
آهن	گوسین	۳	۵۰	۰/۰۰۹۹	۰/۰۰۲۶	۰/۰۰۹۴	۰/۹۹
روی	گوسین	۵	۱۰۰	۰/۰۸۱	۰/۰۲۱	۰/۰۷۷۳	۰/۷۸

شکل ۴-۷ پراکنش داده‌های مشاهداتی و پیش‌بینی شده مربوط به غلظت عنصر آهن در خاک توسط مدل را نشان می‌دهد. همانطور که مشخص است مدل ANFIS با ساختارهای مطرح شده توانسته تا حد قابل قبولی به پیش‌بینی غلظت آهن خاک بپردازد.




شکل ۴-۷: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای عنصر آهن توسط مدل ANFIS

نتایج حاصل برای پیش‌بینی عنصر روی نشان می‌دهد که مدل ANFIS با تابع عضویت گوسین و با تعداد تابع عضویت ۵ بهترین ساختار را ایجاد نموده است. میزان تابع خطا برای مرحله آموزش و آزمون به ترتیب ۰/۰۸۱ و ۰/۰۲۱ بوده است. همچنین میزان خطا در شبیه‌سازی غلظت عنصر آهن ۰/۰۷۷ و میزان ضریب تبیین ۰/۷۸ بوده است.

شکل ۴-۸ پراکنش داده‌های مشاهداتی و پیش‌بینی شده توسط مدل را نشان می‌دهد. همانطور که مشخص است مدل ANFIS با ساختارهای مطرح شده توانسته تا حد قابل قبولی به پیش‌بینی غلظت عنصر روی خاک بپردازد.

تامسون و همکاران (۲۰۰۵) نیز با مدل رگرسیون زمین نما توانستند ۷۰ درصد از تغییرات کربن آلی را پیش‌بینی کنند. مقایسه بین مدل‌های رگرسیونی، شبکه عصبی و شبکه عصبی فازی نشان داد که مقادیر برآورد شده به وسیله شبکه عصبی تطبیقی-فازی دارای بیشترین دقت و روش رگرسیونی دارای کمترین دقت بود. سبزیپرور و بیاتورکشی (۱۳۸۹) نتیجه گرفتند که دقت روش استنتاج تطبیقی عصبی-فازی، ۴ درصد بیشتر از روش آماری رگرسیون است.



شکل ۴-۸: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده در مرحله شبیه‌سازی برای عنصر روی توسط مدل ANFIS

#### ۴-۵ آنالیز حساسیت بر روی پارامترهای ورودی به مدل شبکه عصبی مصنوعی و ANFIS


در بیشتر تحقیق‌های کمی و کیفی پیدا کردن مهم‌ترین عوامل تاثیرگذار به علت پیچیدگی روابط بین متغیرها یکی از دغدغه‌های پژوهشگران بوده است. متغیر وابسته فقط تحت تاثیر یک متغیر مستقل قرار ندارند بلکه تعداد زیادی متغیرهای شناخته شده و شناخته نشده‌ای وجود دارند که متغیر وابسته را تحت تاثیر قرار می‌دهند که این متغیرها نیز ممکن است خودشان تحت تاثیر یک دسته از متغیرهای دیگر باشند. بنابراین تشخیص اینکه کدام متغیر می‌تواند تاثیر بیشتری بر متغیر وابسته بگذارد چالش برانگیز می‌شود. روش‌های مختلفی تحت نام آنالیز حساسیت برای استخراج قوانین حاکم بر مدل هدف به کار برده می‌شوند. با انجام آنالیز حساسیت می‌توان نقش هر یک از پارامترها را لحاظ کرده و تاثیر آن‌ها را محاسبه کرد (مکاریان و روحانی، ۱۳۹۲). تعیین تاثیرگذارترین پارامترها در مقدار عناصر آهن و روی خاک تخمین زده شده نیز با انجام این محاسبه امکان پذیر می‌شود. نتایج آنالیز حساسیت شبکه برا دو عنصر آهن و روی به ترتیب در شکل‌های ۴-۹ و ۴-۱۰ نشان داده شده است. بر اساس نتایج حاصل از آنالیز حساسیت، در پیش‌بینی میزان عناصر دیرپافت

خاک هر ۵ پارامتر ورودی بر روی عناصر آهن و روی خاک تاثیرگذار است. از بین پارامترهای ورودی درصد آهک و رس برای آهن و همچنین درصد رس و هدایت الکتریکی برای عنصر روی پارامتر مهم و اصلی به شمار می‌آید.


نتایج آنالیز حساسیت خروجی مدل ANFIS در شکل‌های ۴-۱۱ و ۴-۱۲ نشان داده شده است. بر اساس نتایج حاصل از آنالیز حساسیت، در پیش‌بینی میزان عناصر دیرپافت خاک هر ۵ پارامتر ورودی بر روی عناصر آهن و روی خاک تاثیرگذار بوده است. از بین پارامترهای ورودی، درصد آهک و رس برای آهن و همچنین هدایت الکتریکی و درصد آهک برای عنصر روی پارامتر مهم و اصلی به شمار می‌آید به گونه‌ای که بیشترین تاثیر را بر خروجی مدل برای پیش‌بینی عنصر آهن و روی خاک دارا بوده اند.

کمبود عناصر کم مصرف خصوصاً آهن در بعضی از گیاهان بدلیل غیر قابل جذب بودن آن‌ها در خاک‌های آهکی از مشکلات اصلی تولید محصولات کشاورزی بوده که کاهش این عناصر بر خصوصیات گیاه و عملکرد آن‌ها اثرات عمده‌ای دارند (مظاهری و همکاران، ۱۳۸۹). مورنا و همکاران (۲۰۰۶) طی یک پژوهش به این نتیجه رسیدن که وجود کربنات کلسیم در خاک با قابلیت دسترسی و ظرفیت نگهداری آهن خاک ارتباط دارد.


در مورد میزان رس باید خاطر نشان کرد که هرچه سطح تبادل خاک بیشتر باشد میزان جذب عناصر آهن و روی نیز بیشتر می‌شود. پس طبیعی است که یک همبستگی قوی بین میزان عناصر و مقدار رس خاک مشاهده شود. شدت کاهش آهن و روی کل اندام هوایی گیاهان در خاک شنی بیشتر از خاک لوم رسی سیلتی بود که دلیل این امر احتمالاً مقدار بیشتر سایت‌های تبدالی موجود در خاک ریزبافت نسبت به خاک درشت بافت است که عناصر غذایی بیشتری حتی در شرایط آهکی در اختیار گیاه قرار داده است.




شکل ۴-۹: آنالیز حساسیت درصد خطا سهم پارامترهای ورودی در تخمین میزان عنصر آهن خاک مدل ANN



شکل ۴-۱۰: آنالیز حساسیت درصد خطا سهم پارامترهای ورودی در تخمین میزان عنصر روی خاک مدل ANN



شکل ۴-۱۱: آنالیز حساسیت سهم پارامترهای ورودی در پیش‌بینی میزان عنصر آهن خاک مدل ANFIS



شکل ۴-۱۲: آنالیز حساسیت سهم پارامترهای ورودی در پیش‌بینی میزان عنصر روی خاک مدل ANFIS

۶-۴ اجرای مدل سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی

خاک


اجرای مدل سیستم استنتاج تطبیقی عصبی فازی نیز توسط نرم‌افزار MATLAB 2015 انجام گردید و برای اینکه بتوان برتری دو مدل شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی فازی را برای پیش‌بینی عناصر دیریافت خاک تعیین کرد، پارامترهای ورودی به هر دو نوع مدل یکسان در نظر گرفته شد. در سیستم استنتاج فازی عصبی تطبیقی، ابتدا ساختار مدل با مشخصه‌های مشخص، که متناسب با ورودی‌ها، درجه عضویت و قوانین و توابع درجه عضویت خروجی است، انتخاب می‌شود. در مدل انفیس تمامی توابع عضویت `trimf`, `trapmf`, `gbellmf`, `gaussmf`, `gaussmf2`, `pimf`, `dsigmf`, `psigmf` از بهترین تابع محرک مدل سیستم استنتاج تطبیقی عصبی فازی برای پیش‌بینی عناصر آهن و روی خاک در جدول ۴-۶ نشان داده شده است. نتایج حاصل برای پیش‌بینی عنصر آهن نشان می‌دهد که مدل ANFIS با تابع عضویت گوسین و با تعداد تابع عضویت ۳ بهترین ساختار را در پیش‌بینی غلظت عنصر آهن خاک ایجاد نموده است. میزان تابع خطا برای مرحله آموزش و آزمون به ترتیب ۰/۰۰۹۹ و ۰/۰۰۲۶ بوده است. همچنین میزان خطا در شبیه‌سازی غلظت عنصر آهن ۰/۰۰۹۴ و میزان ضریب تبیین ۰/۹۹ برای این عنصر بوده است.

جدول ۴-۶ نتایج حاصل از اجرای بهترین ساختار شبکه ANFIS برای پیش‌بینی عنصر آهن و روی خاک

خروجی مدل	نوع تابع عضویت	تعداد توابع عضویت	تکرار	خطای آموزش	خطای آزمون	خطای شبیه‌سازی (RMSE)	ضریب تبیین شبیه‌سازی
آهن	گوسین	۳	۵۰	۰/۰۰۹۹	۰/۰۰۲۶	۰/۰۰۹۴	۰/۹۹
روی	گوسین	۵	۱۰۰	۰/۰۸۱	۰/۰۲۱	۰/۰۷۷۳	۰/۷۸

شکل ۴-۱۳ پراکنش داده‌های مشاهداتی و پیش‌بینی شده مربوط به غلظت عنصر آهن در خاک توسط مدل را نشان می‌دهد. همانطور که مشخص است مدل ANFIS با ساختارهای مطرح شده توانسته تا حد قابل قبولی به پیش‌بینی غلظت آهن خاک بپردازد.






شکل ۴-۱۳: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای عنصر آهن توسط مدل ANFIS

نتایج حاصل برای پیش‌بینی عنصر روی نشان می‌دهد که مدل ANFIS با تابع عضویت گوسین و با تعداد تابع عضویت ۵ بهترین ساختار را ایجاد نموده است. میزان تابع خطا برای مرحله آموزش و آزمون به ترتیب ۰/۰۸۱ و ۰/۰۲۶ بوده است. همچنین میزان خطا در شبیه‌سازی غلظت عنصر آهن ۰/۰۲۱ و میزان ضریب تبیین ۰/۷۸ بوده است.

شکل ۴-۱۴ پراکنش داده‌های مشاهداتی و پیش‌بینی شده توسط مدل را نشان می‌دهد. همانطور که مشخص است مدل ANFIS با ساختارهای مطرح شده توانسته تا حد قابل قبولی به پیش‌بینی غلظت عنصر روی خاک بپردازد.

تامسون و همکاران (۲۰۰۵) نیز با مدل رگرسیون زمین نما توانستند ۷۰ درصد از تغییرات کربن آلی را پیش‌بینی کنند. مقایسه بین مدل‌های رگرسیونی، شبکه عصبی و شبکه عصبی فازی نشان داد که مقادیر برآورد شده به وسیله شبکه عصبی تطبیقی-فازی دارای بیشترین دقت و روش رگرسیونی دارای کمترین دقت بود. سبزیپور و بیاتورکشی (۱۳۸۹) نتیجه گرفتند که دقت روش استنتاج تطبیقی عصبی-فازی، ۴ درصد بیشتر از روش آماری رگرسیون است.

سبزی پرور و همکاران (۱۳۸۹) طی یک پژوهش ضمن استفاده از مدل‌های رگرسیونی، با بکارگیری سامانه استنتاج تطبیقی عصبی- فازی (ANFIS) به عنوان روشی نوین، به پیشبینی دمای خاک در شش عمق مختلف (۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰) سانتی متر اقدام کردند. علاوه بر این، مهمترین پارامترهای هواشناسی (دمای بیشینه، دمای کمینه، میانگین دمای روزانه، رطوبت نسبی، ساعات آفتابی و سرعت باد) به عنوان عوامل اثرگذار بر دمای خاک در یک دوره ۱۵ ساله ۲۰۰۶-۱۹۹۲ در ایستگاه‌های مورد مطالعه معرفی میگردند. مطالعه روی داده‌های هواشناسی ۳ ایستگاه سینوپتیک زاهدان، تهران و رامسر که دارای اقلیم متفاوتی میباشند، انجام دادند. یافته‌ها حاکی از ۴ درصد دقت بیشتر روش ANFIS نسبت به روش آماری رگرسیون بود. همچنین دقت پیشبینی دمای خاک با روش ANFIS در دو ایستگاه زاهدان و تهران (اقلیم خشک) به ترتیب ۱۲ درصد و ۴/۵ درصد بهتر از رامسر (اقلیم مرطوب) بوده است.



شکل ۴-۱۴: نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای عنصر روی توسط مدل ANFIS

#### ۴-۷ مقایسه مدل‌های شبکه عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی فازی

نتایج حاصل از مقایسه دو مدل مورد استفاده در برآورد غلظت عنصر آهن خاک در جدول ۴-۴-۳ و ۴-۵ آورده شده است. طبق جدول مذکور مشاهده می‌شود که مدل ANFIS با داشتن ضریب تبیین ۰/۹۹ برای عنصر آهن خاک نسبت به مدل شبکه عصبی مصنوعی با داشتن ضریب تبیین ۰/۹۳ و ۰/۹۱ به ترتیب برای تابع محرک تانژانت سیگموئید و لگاریتم سیگموئید در مرحله شبیه سازی بهترین کارایی را دارد. نتایج حاصل از مقایسه دو مدل مورد استفاده برای برآورد غلظت روی در جدول ۴-۴ و ۴-۵ آورده شده است. طبق جدول مذکور مشاهده می‌شود که مدل ANFIS با داشتن ضریب تبیین ۰/۷۸ برای عنصر روی خاک نسبت به مدل شبکه عصبی مصنوعی با داشتن ضریب تبیین ۰/۳۱ و ۰/۳۰ به ترتیب برای تابع محرک تانژانت سیگموئید و لگاریتم سیگموئید در مرحله شبیه سازی بهترین کارایی را داشته است.



# فصل پنجم

## نتیجہ گیری و مشہادہ

## نتیجه گیری

۱- میزان ضریب تبیین مدل ANFIS نسبت به شبکه عصبی بیشتر و میزان خطای آزمون، خطای آزمایش و خطای شبیه سازی برای هر دو عنصر آهن و روی مقادیر بالاتری در شبکه عصبی نسبت به مدل ANFIS دارد، که نشان دهنده کارایی پایین تر مدل شبکه عصبی مصنوعی نسبت به مدل ANFIS دارد.

۲- عنصر آهن با درصد رس و ماده آلی و همچنین عنصر روی با اسیدیتته و هدایت الکتریکی بیشترین همبستگی را دارند.

## پیشنهادها

● با توجه به نیاز اراضی کشاورزی منطقه برای گسترش روش های پیش بینی و شبیه سازی برای عناصر به ویژه عناصر کم مصرف و هزینه نسبتا زیاد اندازه گیری این عناصر، استفاده از شبکه هوش مصنوعی و سیستم استنتاج فازی برای استفاده بهینه از کودهای میکرو و ماکرو روش توصیه می گردد.

● استفاده از تعداد نمونه بیشتر جهت رسیدن به نتایج دقیق و جامع.

● شناسایی و استفاده از ریزجاندارن بومی خاک از جمله قارچ ها و باکتری های بومی در ترکیب با

گیاهان بومی خاک های آلوده نفتی جهت اصلاح این خاک ها.

## فهرست منابع (فارسی و لاتین)

احمدزاده قره‌گویز ک.، میرلطیفی م. و محمدی ک. (۱۳۸۹) "مقایسه سیستم‌های هوش مصنوعی در نخمین میزات تبخز - تعرق گیاه مرجع در مناطق بسیار خشک ایران" نشریه آب و خاک. جلد ۲۴، شماره ۴، ص ۶۸۹-۶۷۹.

احیائی م. و بهبهانی‌زاده ع. (۱۳۷۲). "شرح روش‌های تجزیه شیمیایی خاک" موسسه تحقیقات خاک و آب. نشریه ۸۹۳. جلد اول.

آرمین م.، احمدی ح.، روحی پور ح.، سلاجقه ع.، مهدیان م.ر. و قربان نیا خیبری و (۱۳۹۴). "ارزیابی پایداری خاکدانه‌ها و تعیین مکانیسم ناپایداری خاک‌های حوضه آبخیز طالقان". مرتع و آبخیزداری، ۶۸(۴)، ۶۹۱-۷۱۰.

امجدیان ا.، قنبری ا. و خمیری ع. (۲۰۱۷) "بررسی مدیریت تغذیه گیاه تحت تاثیر عناصر ماکرو و میکرو در دانه گندم" مجله بوم‌شناسی کشاورزی. جلد ۱۰. شماره ۱.

امیرانتظاری ک.، وکیل باغمیشه م.ت. و حسن‌زاده ا. (۱۳۸۸). "بررسی و ارائه روش‌های نوین آموزش شبکه عصبی با استفاده از الگوریتم‌های نوین هوش مصنوعی" دانشگاه تبریز. دانشکده مهندسی برق و کامپیوتر گروه کنترل.

ایمانی ر.، قاسمیه ه. و اسمعلی عوری. (۱۳۹۵) "مقایسه کارایی مدل هیدرولوژیکی WetSpa، شبکه عصبی مصنوعی و سیستم عصبی - فازی انطباقی در شبیه‌سازی دبی جریان رودخانه" نشریه آب و خاک. جلد ۲۶. شماره ۱. ص ۹۹-۱۱۶.

بازوبندی ا.، قربانی ه. و امامقلی‌زاده ص. (۱۳۹۴)، "تخمین کادمیوم کل خاکب استفاده از خصوصیات خاک به کمک شبکه‌ی عصبی"، کنفرانس ملی دستاوردهای نوین در علوم زیستی و کشاورزی، زابل.

بانژاد ح.، محب‌زاده ح. و علیائی ا. (۲۰۱۳) " کاربرد شبکه عصبی مصنوعی و GIS در تخمین پارامتر-  
های موثر در تعیین الگوی کشت " فصلنامه علوم و تکنولوژی محیط زیست. دوره ۱۵. شماره ۱.  
صفحه ۲۳-۳۵.

برزگر ع.ر. (۱۳۸۷) " کتاب خاک‌های شور و سدیمی با محوریت کشاورزی. نوبت چاپ اول.

بوستانی م.، چرم م.، معزی ع.، کریمیان ن.، عنایتی ضمیر ن. و زارعی م. (۱۳۹۵). " اثر کاربرد  
باکتری‌های محرک رشد گیاه و قارچ میکوریز آرباسکولار بر توزیع شکل‌های شیمیایی روی در یک  
خاک آهکی با سطوح مختلف شوری " .مجله مدیریت خاک و تولید پایدار. ۲۴-۱.

پیچند م. (۱۳۹۶). مطالعه تأثیر تبدیل مرتع به سایر کاربری‌های کشاورزی بر برخی خصوصیات  
فیزیکی و شیمیایی خاک (مطالعه موردی: حوزه آبخیز امامه). اکوسیستم های طبیعی ایران، ۸(۱)،  
۹۹-۱۲۲.

حسین‌زاده ج.، نامور آ.، حیاتی ب. و پیش بهار ا. (۱۳۹۳) " تعیین الگوی کشت محصولات زراعی با  
تاکید بر کشاورزی پایدار در اراضی زیر سد علویان " نشریه دانش کشاورزی و تولید پایدار، جلد ۲۴.  
شماره ۲.

داودی معمار ل. و فلاح ع.ر. (۱۳۹۲) "استفاده از نقشه حاصلخیزی در پراکنش عناصر میکرو و ماکرو  
المنت در کاهش مصرف کودهای شیمیایی در راستای تحقق، توسعه و پایداری" کنفرانس علوم  
کشاورزی و محیط‌زیست.

رشادصدقی ع. و محمودی ا. (۱۳۹۶). "مقایسه کارایی مدل‌های شبکه عصبی مصنوعی و آنفیس در  
درجه‌بندی آکوستیک ارقام مختلف بادام". پژوهش های مکانیک ماشینهای کشاورزی، ۶(۱۱)، ۳۱-  
۴۰.



سبزی پرور ع.ا.، زارع ابیانه ح. و بیات م. (۱۳۸۹) "مقایسه یافته‌های مدل شبکه استنتاج تطبیقی عصبی - فازی با مدل رگرسیونی به منظور برآورد دمای خاک در سه اقلیم متفاوت" نشریه آب و خاک علوم و صنایع کشاورزی. جلد ۲۴. شماره ۲، خرداد - تیر ۱۳۸۹. ص. ۲۸۵ - ۲۷۴.

سلیمان زاده م.، خادمی ح. و سپهری م. (۱۳۹۵) " توانایی دو گونه گیاهی در جذب آهن از بسترهای حاوی فلوگوپیت و مسکویت " نشریه آب و خاک، جلد ۳۱، شماره ۲، ص ۴۴۹-۴۵۹.

شریفی گرم‌دره ا.، وفاخواه م. و اسلامیان س. (۱۳۹۳) " مقایسه کارآیی سامانه‌های استنتاج فازی - عصبی تطبیقی و ماشین‌بردار پشتیبان در تحلیل منطقه‌ای سیلاب در حوزه آبخیز دریاچه نمک " پایان نامه کارشناسی ارشد مهندسی آبخیزداری دانشگاه تربیت مدرس. ۱۳۰ صفحه.

شهابی قویونلویی م.، رفیعی ش.، محتسبی س.س. و حسین‌پور س. (۱۳۹۲) "کاربرد شبکه هوش مصنوعی و استنتاج عصبی فازی تطبیقی برای تعیین محتوای رطوبتی برگ چای سبز براساس پارامترهای رنگی" مجله مهندسی بیوسیستم ایران. دوره ۴۴. شماره ۲. ص ۱۳۳-۱۲۵.

کریمی دهکردی ف.، جلالیان ا.، محنت‌کش ع. و هنرجو ن. (۱۳۹۳) " اثر موقعیت شیب و تغییر کاربری اراضی بر خصوصیات کانی‌شناسی بخش رس خاک و خصوصیات میکرومورفولوژی خاک در منطقه لردگان استان چهارمحال و بختیاری " نشریه مدیریت خاک و تولید پایدار، جلد ۴، شماره ۳.

کیا ع.، عمادی ع.ر. و فضل‌اولی ر. (۱۳۹۴) " بررسی امکان کاربرد استنتاج عصبی فازی - عصبی تطبیقی در برآورد روسوبات بابل ". پژوهش مدیریت آبخیزسال ششم. شماره ۱۱.

محرم نژاد ن. و تهرانی م. (۱۳۸۹) " مروری بر نظریه‌های اجتماعی و مدیریت محیط زیست: انسان و محیط زیست، ۸، ۱۱-۳.

محمدی سلطان آباد ز، اسفندیاری درآباد ف، سبحانی ب. و فاضلی ع. (۱۳۹۲) "تحلیل عملکرد شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی در پیش بینی و برآورد فرسایش و رسوب حوضه نوران". پایان نامه دوره کارشناسی ارشد.

Article I محمدی منور ح. و باقرپور ح. (۱۳۹۶). "کاربرد روش طیفسنجی مرئی و فرو

سرخ نزدیک در تشخیص آلودگی خاک به کادمیوم و سرب با مدل سازی رگرسیونی و شبکه

عصبی مصنوعی" مهندسی بیوسیستمی ایران. دوره ۴۸. شماره ۱.

معماریان فرد م. و بیگی ح. (۱۳۸۸). "مقایسه مدل های شبکه عصبی مصنوعی و توابع انتقالی رگرسیونی برای پیش بینی ظرفیت تبادل کاتیونی خاک های استان چهارمحال بختیاری" نشریه آب و خاک (علوم و صنایع کشاورزی). جلد ۲۳. شماره ۴. ص ۹۰-۹۹.

مظاهری نیا س، آستارائی ع، فتوت ا. و منشی ا. (۱۳۸۹) "مقایسه اکسیدهای آهن معمولی و نانو ضایعاتی بر جذب و تجمع آهن در گیاه گندم در یک خاک آهکی" اولین همایش ملی کشاورزی و توسعه پایدار، فرصت و چالش های پیش رو.

مکاریان ح. و روحانی ک. (۱۳۹۲). "پیش بینی الگوی توزیع مکانی جمعیت علف هرز تلخه (*Acroptilonrepens L*) با استفاده از مدل شبکه عصبی مصنوعی بردار چندی ساز یادگیر (LVQ)" نشریه دانش کشاورزی. دوره ۲۳. شماره ۱.

مکرم م، مکرم م. ج، زارعی ع. ر. و صفری نژادیان ب. (۱۳۹۶) "استفاده از شبکه عصبی - فازی تطبیق پذیر (ANFIS) به منظور پیس بینی کیفیت آب زیرزمینی در غرب استان فارس طی سال های ۱۳۸۳ تا ۱۳۹۳" مجله اکوهیدرولوژی. دوره ۴. شماره ۲. ص ۵۴۷-۵۵۹.

ملائی رنانی م، بشری ح، بصیری م. و مصدقی م. ر. (۱۳۹۴). "ارزیابی پایداری ساختمان خاک به روش الگ تر در برخی از مکان های مرتعی استان اصفهان". نشریه علوم آب و خاک-علوم و فنون کشاورزی و منابع طبیعی-Isfahan University of Technology, ۱۸(۷۰), ۱۲۱-۱۳۳.

ملکوتی م.ج. و غیبی م.ن. (۱۳۸۴) "ضرورت کود پتاسیم در ذرت (افزایش محصول و بهبود کیفیت)" انتشارات سنا، مؤسسه تحقیقات خاک و آب.

موسوی نژاد س. (۱۳۸۵) ستارگان پراکنده ایران زمین، در ذکراحوال امامزادگان کرانه‌های جنوبی خلیج فارس و دامنه شمالی و شرق جبال زاگرس (کهگیلویه و بویراحمد) چاپ اول، قم: انتشارات کومه.

موسوی نژاد س. (۱۳۸۵) ستارگان پراکنده ایران زمین، در ذکراحوال امامزادگان کرانه‌های جنوبی خلیج فارس و دامنه شمالی و شرق جبال زاگرس (کهگیلویه و بویراحمد) چاپ اول، قم: انتشارات کومه.

نصرت پور س.، محمدی ا.، فرج‌نیا ا. و اسمعیلی عوری ا. (۱۳۸۹). "بررسی توزیع مکانی برخی عناصر غذایی و عوامل موثر بر حاصلخیزی خاک در اراضی شهرستان مراغه با استفاده از سامانه اطلاعات جغرافیایی. پژوهش و سازندگی (پژوهش و آبخیزداری). ۸۷: ۱-۱۱.

هاتف فرد ف.، خاموشی س.ع. و موسوی س.م. (۱۳۹۴) "اهمیت و جایگاه خاک در کشاورزی پایدار و امنیت غذایی" سومین همایش ملی انجمن‌های علمی دانشجویی رشته‌های کشاورزی و منابع طبیعی. ۱-۸.

Abbaspour A, Kalbasi M, Hajrasuliha S, Fotovat A (2008) Effect of Organic Matter and Salinity on Ethylenediaminetetraacetic Acid-Extractable and Solution Species of Cadmium and Lead in Three Agricultural Soils Communications in soil science and plant analysis 39:983-1005.

Aghdam I.N., Pradhan B., and Panahi M. (2017). Landslide susceptibility assessment using a novel hybrid model of statistical bivariate methods (FR and WOE) and adaptive neuro-fuzzy inference system (ANFIS) at southern Zagros Mountains in Iran. Environmental Earth Sciences, 76(6), 237.

Alaai M., Zanguy M. and Zanguy H. (2015). Prediction of water quality using neural networks MLP and adaptive fuzzy inference system (ANFIS) in Neyshabur plain. The National Conference of Environmental Science and Engineering Ahvaz.

Al-Mustafa W., Abdallah A. and Falatah, A. (2001). Assessment of five extractants for their ability to predict iron uptake and response of sorghum grown in calcareous soils. *Communications in Soil Science and Plant Analysis*, 32(5-6): 907-919.

Asif M., Yilmaz O. and Ozturk L. (2017). Elevated carbon dioxide ameliorates the effect of Zn deficiency and terminal drought on wheat grain yield but compromises nutritional quality. *Plant and Soil*, 411(1-2), 57-67.

Bigdeli, Mostafa (2010), artificial of neurology, University of Qazvin (Raja), Iran, Oct 14, 2010.

Boostani H.R., Chorom M., Moezzi A., Karimian N. and Enayatizamir N. (2017). Effect of Salinity and Organic Matter on Distribution of Zinc Chemical Forms in a Calcareous Soil after Maize Cultivation. *Water and Soil Science*. 27: 1. 1-10.

Cakmak I., McLaughlin M. J. and White P. (2017). Zinc for better crop production and human health.

Cakmak I., Pfeiffer W.H., and McClafferty B. (2010). Biofortification of durum wheat with zinc and iron. *Cereal Chemistry*, 87: 10-20.

Chokshi P., Dashwood R. and Hughes D. J. (2017). Artificial Neural Network (ANN) based microstructural prediction model for 22MnB5 boron steel during tailored hot stamping. *Computers & Structures*, 190, 162-172.

Chowdhury A., Ghosh A., Gupta D. and Viswavidyalaya C. K. (2017). Assessment of Total Dissolved Solid Concentration in Groundwater of Nadia District, West Bengal, India using Artificial Neural Network. *Assessment*, 6(10).

Darvari Z., Gholami V. and Derakhshan S. (2015) Simulated groundwater salinity using artificial neural network (ANN) in coast of the Mazandaran province. *Journal of Water and Irrigation*. 36(2): 61-70.

Fageria N. K. (2010). *The use of nutrients in cropplants* (1th ed.). New York: CRC Press.

French J., Mawdsley R., Fujiyama T. and Achuthan K. (2017). Artificial Neural Network forecasting of storm surge water levels at major estuarine ports to supplement national tide-surge models and improve port resilience planning. In *EGU General Assembly Conference Abstracts* (Vol. 19, p. 15018).

Jang J. S. R.,(1993)," ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans*",*Sys., Man, Cyb.*, 23, 665–685.

Hafeez Y., Khanif M. and Saleem M. (2013). Role of zinc in plant nutrition". *American Journal of Experimental Agriculture*. 304-391.

Hajabbasi M.A., Besalatpour A., Melali A.R. (2008). Impacts of Converting Rangelands to Cultivated Land on Physical and Chemical Properties of Soils in West and Southwest of Isfahan, 11(42): 525-534.

Hannam I, Boer B (2002) *Legal and Institutional Frameworks for Sustainable soil: a preliminary report*. vol 45. IUCN

Houghton P.D. and Charman P. (1986) "Glossary of terms used in soil conservation" Soil Conservation Service of NSW

Kabata-Pendias A. (2011). Trace Elements in Soils and Plants. 3rd Ed. CRC Press. Boca Raton, FL.

Karami B. and Golabi M. (2013) Simulate and predict water quality parameters using artificial neural networks, fuzzy neural and statistical regression (Case study: Karun river, Khuzestan province)." The ninth international seminar river. Ahvaz martyr Chamran University.

Kashi H., Ghorbani H., Emamgholizadeh S. and Hashemi S.A.A. (2012). Effect of land use change on physico-chemical, (Case area: Ghoshe Land water spreading and agriculture land in Semnan Province), Journal of Water and Soil Science, 18(67):187-199.

Khademi Z., Jones D L., Malakouti M. J., Asadi F., and Ardebili M. (2009). Organic acid mediated nutrient extraction efficiency in three calcareous soils. Soil Research, 47(2), 213-220.

Kisi O., Sanikhani H. and Cobaner M. (2017). Soil temperature modeling at different depths using neuro-fuzzy, neural network, and genetic programming techniques. Theoretical and Applied Climatology, 129(3-4), 833-848.

Kizilkaya R. and Dengiz O. (2010). Variation of land use and land cover effects on some soil physico-chemical characteristics and soil enzyme activity. Zemdirbyste Agriculture, 97: 15-24.

Maia, S.M.F., Ogle, S.M., Cerri, C.C., & Cerri, C.E.P. (2010). Changes in soil organic carbon storage under different agricultural management systems in the Southwest Amazon Region of Brazil. Soil & Tillage Research, 106:177–184.

Marschner H. (2008). Mineral Nutrition of Higher Plants. 2ndEd., Academic Press. Landan. UK.

Marschner H. and Marschner P. (2012). Marschner's mineral nutrition of higher plants, (3th ed.). Australia: Academic press.

Mazzocchi C., Corsi S., and Sali G. (2017). Agricultural land consumption in periurban areas: a methodological approach for risk assessment using artificial neural networks and spatial correlation in Northern Italy. *Applied Spatial Analysis and Policy*, 10(1), 3-20.

Morna A.M., Ramon Quintana J., Perez L. and Parra J.G. (2006). Factors influencing lead sorption-desorption at variable added metal concentrations in Rhodoxeralfs. *Chemosphere*. 64: 758-763

Nieto P.G., García-Gonzalo E., Bové J., Arbat G., Duran-Ros M., and Puig-Bargués J. (2017). Modeling pressure drop produced by different filtering media in microirrigation sand filters using the hybrid ABC-MARS-based approach, MLP neural network and M5 model tree. *Computers and Electronics in Agriculture*, 139, 65-74.

Niknahad Gharmakher, H and Maramaei, M., (2011). Effects of land use changes on soil properties (Case Study: the Kechik catchment), *Journal of Soil Management and Sustainable*, 1(2): 81-96.

Patel V.I. Saravaita S.N Arvadia M.K. Chaudhari J.H. Ahir M.P. and Bhalerao R.E. (2010). Effects of conjunctive use of bio-organics and inorganic fertilizers on growth, yield and economics of Rabi Fennel (*Foeniculum vulgare* Mill.) under south Gujarat conditions. *International journal of Agricultural sciences*. Vol. 6 Issue 1: 178-181

Pentoś K. and Pieczarka K. (2017). Applying an artificial neural network approach to the analysis of tractive properties in changing soil conditions. *Soil and Tillage Research*, 165, 113-120.

Roy D.K. and Singh B.P. (2006). Effects of level and time of nitrogen application with and without vermicompost on yield, yield component and quality of malt barley (*Hordeum vulgar*). *Indian Journal of Agronomy*. 51(1): 40- 42.

Shahbazi K. and Besharati H. (2013). Short investigation of soil fertility status of Iran. *J. Land Manage.* 1: 1-15.

Subramanian K.S., Tensia V., Jayalakshmi K. and Ramachandran V. (2009). Biochemical changes and zinc fractions in arbuscular mycorrhizal fungus (*Glomus intraradices*) inoculated and non-inoculated soils under differential zinc fertilization. *Appl. Soil Ecol.* 49: 32-39.

Tabari H., Marofi S., Hosseinzadeh Talaei P. and Mohammadi K. (2011). Trend analysis of reference evapotranspiration in the western half of Iran. *Agric. For. Meteorol.* 151, 128–136

Taheri-Rad A., Khojastehpour M., Rohani A., Khoramdel S. and Nikkha A. (2017). Energy flow modeling and predicting the yield of Iranian paddy cultivars using artificial neural networks. *Energy*, 135, 405-412.

Tang L, Zeng G.M, Nourbakhsh F. and Shen G.L, (2008), " Artificial neural network approach for predicting cation exchange capacity in soil based on physico-chemical properties", *Environ. Eng. Sci*, 26(2): 1-10.

Vijayakumar R., Arokiaraj A. and Martin DevaPrasath P. (2011). Micronutrients status and their relation to soil characteristics of south-



eastCoastal soils of INDIA. International Journal of Research in Chemistry and Environment, 147- 150.

Vlontzos G., and Pardalos P. M. (2017). Assess and prognosticate green house gas emissions from agricultural production of EU countries, by implementing, DEA Window analysis and artificial neural networks. Renewable and Sustainable Energy Reviews, 76, 155-162.

Walkley A. and Black I.A. (1934). An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. Soil science, 37(1), 29-38.

Qishlaqi A., Moore F. and Forghani G. (2009). Characterization of metal pollution in soils under twolanduse patterns in the Angouran region, NW Iran;a study based on multivariate data analysis. Journal of Hazardous Materials, 384-172:374.

## Abstract

In this study, using the Artificial Neural network (ANN) and adaptive-fuzzy inductive inference system (ANFIS) have used to predict some soil micro elements. The study was carried out in the city of Cherram and Dehdasht with 90 surface soil samples. For this purpose, easily found soil parameters such as soil lime, pH, EC and organic matter, iron and zinc were used as input data to the model. The results revealed that correlation between iron and zinc elements with input parameters showed the highest correlation between organic matter and clay content with the iron element, acidity and electrical conductivity with soil elements. The results of perceptron network (MLP) for calculating iron and zinc elements showed that the best explanation coefficient was compared with other functions related to Gaussian function, which was 0.93 for sigmoid tangent and 0.91 for sigmoid logarithm, and 0.31 for the sigmoid tangent, 0.3 for the sigmoid logarithm for iron and zinc, respectively. The results of the implementation of the Fuzzy Adaptive Inference System model for prediction of iron and zinc elements illustrated that ANFIS model with Gaussian membership function for both iron and zinc elements and having a coefficient of 0.99 for iron as well as a coefficient of explanation of 0.78 for zinc has the best mode over other functions. The results of the comparison of the two models indicate that the ANFIS model has a coefficient of 0.99 and 0.78 for iron and zinc elements, respectively, compared with the artificial neural network model with a coefficient explanation of 0.93 and 0.91, and also, 0.31 and 0.30 are the best in iron and zinc elements, respectively, in the training and certification phases. The ANFIS model's explanation coefficient is higher than the neural network, and the error rate of the test, the test error and the simulation error for iron and zinc elements in the neural network are higher, which indicates the lower efficiency of the artificial neural network model compared to ANFIS model.

## Keywords

Artificial neural network, ANFIS, iron, zinc



**Faculty of Agriculture**

**M.Sc. Thesis in Soil Chemistry and Fertility**

**Prediction of Soil Fe and Zn Concentration in Dehdasht and Choram**

**Using Artificial Neural Neural Network (ANN) and Adaptiv Neuro**

**Fuzzy Interface System (ANFIS) Models**

**By: zohre padash**

**Supervisors:**

**D.r: Hadi Ghorbani**

**D.r: Shahin Shabsavani**

**Advisor:**

**D.r: Vajiheh Dorostkar**

**June 2018**