



## بررسی کارآیی روش های داده مبناء در تخمین ظرفیت زراعی و نقطه پژمردگی

دائم

امید نوروزی انگنایی<sup>۱</sup>

۱- فوق لیسانس مهندسی عمران، مسئول متره برآورد کارگاه احداث راه آهن چابهار به زاهدان، موسسه پایدار سازان

(omidnorozi67@gmail.com)

### چکیده

آگاهی از نقاط مهم رطوبتی، برای مطالعات آبیاری در مزرعه بسیار مهم و ضروری می باشد اما اندازه گیری آنها به روش مستقیم بسیار پرهزینه و وقت گیر است. روش های داده مبناء می توانند روش مناسبی برای تخمین این پارامترها باشد. تحقیق حاضر به برآورد نقاط مهم رطوبتی شامل ظرفیت زراعی و نقطه پژمردگی دائم به وسیله پارامترهای زودیاقت با سه روش شبکه عصبی، رگرسیون خطی چندمتغیره و رگرسیون بردار پشتیبان در منطقه شاهرود پرداخته است. داده های مورد استفاده از مرکز تحقیقات خاک شاهرود گرفته شده است. پس از مرتب سازی داده های مورد نظر جدول ضریب همبستگی متغیرهای ورودی احتمالی با خروجی های مورد نظر تشکیل شد و معنی داری همبستگی متغیرهای ورودی و خروجی از نظر آماری بررسی گردید. پس از نرمال سازی داده ها، مدل سازی با روش های مذکور انجام و نتایج مورد ارزیابی قرار گرفت. نتایج نشان داد که روش رگرسیون بردار پشتیبان کارایی بهتری نسبت به دو روش دیگر دارد. مقادیر ضریب تعیین، میانگین جذر مجموع مجذور انحرافات خطا و ریشه میانگین مربعات خطا نرمال شده در بهترین مدل، به ترتیب برابر ۰/۸۵، ۳/۱۲ و ۱۲/۸۹ برای ظرفیت زراعی و ۰/۸۳، ۱/۵۸ و ۱۴/۸۴ برای نقطه پژمردگی دائم بدست آمده است. **کلمات کلیدی:** شبکه های عصبی مصنوعی، رگرسیون بردار پشتیبان، ظرفیت زراعی، نقطه پژمردگی دائم، منطقه شاهرود.



# ماهنامه علمی تخصصی پایا شهر



## ۱- مقدمه

منحنی مشخصه آب خاک که بیانگر تغییرات رطوبت در برابر مکش آب خاک است، در مسائل مربوط به حرکت آب در خاک غیراشباع کاربرد فراوان دارد و شناسایی رفتار فیزیکی خاک در رطوبت‌های مختلف را آسان‌تر می‌کند. نقاط مهم رطوبتی شامل ظرفیت زراعی و نقطه پژمردگی دائم از عوامل مهم در رسم منحنی مشخصه رطوبتی هستند. اندازه‌گیری نقاط مهم رطوبتی در آزمایشگاه وقت گیر و پرهزینه است، بنابراین، مدل‌ها و روابطی تحت عنوان توابع انتقالی<sup>۱</sup> توسعه یافته‌اند که خصوصیات هیدرولیکی خاک را به‌طور غیر مستقیم با استفاده از داده‌های زودیاخت خاک و با کمک یکسری روابط ریاضی مناسب پیش‌بینی می‌کنند (نگئین و همکاران<sup>۲</sup>، ۲۰۱۵).

توابع انتقالی اولین بار توسط بوما<sup>۳</sup> در سال ۱۹۸۹ پیشنهاد شد و در مسائل مربوط به فیزیک خاک به‌کار گرفته شد (مینانسی و مک برنتی<sup>۴</sup>، ۱۹۹۹). از آنجا که اندازه‌گیری نقاط مهم رطوبتی، کاری وقت گیر، پرهزینه و دشوار می‌باشد، کوشش‌های زیادی به‌عمل آمده است که بتوان این نقاط را با استفاده از ویژگی‌های ساده‌تر خاک مانند بافت، مقدار ماده آلی و چگالی ظاهری به‌دست آورد. توابع انتقالی خاک در واقع توابع پیش‌بینی کننده می‌باشند که ارتباط بین داده‌های زودیاخت خاک (مانند درصد شن، سیلت و رس، جرم مخصوص ظاهری و مواد آلی) را با داده‌های دیریاخت خاک مانند پارامترهای منحنی رطوبتی (ظرفیت‌زراعی و نقطه‌ی پژمردگی دائم) برقرار می‌سازد (بوتولا و همکاران<sup>۵</sup>، ۲۰۱۳). البته توابعی که می‌توانند در یک منطقه به‌طور موفقیت آمیزی به‌کار روند، ممکن است در منطقه جدید سازگاری مناسبی با مقادیر واقعی نداشته باشند. روش‌های مختلفی برای به‌دست آوردن توابع انتقالی وجود دارد که از جمله می‌توان به مدل‌های رگرسیون خطی<sup>۶</sup> (LR)، شبکه‌های عصبی مصنوعی<sup>۷</sup> (ANN)، استنتاج تطبیقی-عصبی فازی<sup>۸</sup> (ANFIS) و رگرسیون بردار پشتیبان<sup>۹</sup> (SVR) اشاره نمود.

محققین مختلفی به توسعه توابع انتقالی در علوم آب و خاک پرداخته‌اند. به‌عنوان نمونه شاپ و لگی<sup>۱۰</sup> (۱۹۹۸) با استفاده از شبکه عصبی منحنی رطوبتی خاک را تخمین زدند. آنها دریافتند که شبکه عصبی مصنوعی به‌کار رفته بهتر از تعدادی از توابع انتقالی رگرسیونی ارائه شده توسط سایر محققان بوده و معمولاً اگر خصوصیات زودیاخت بیشتری به‌عنوان ورودی به کار رود صحت پیش‌بینی‌ها افزایش می‌یابد ولی همیشه اختلاف قابل توجهی بین مقادیر رطوبت پیش‌بینی شده و اندازه‌گیری شده وجود دارد.

ولی و همکاران در سال ۱۳۸۸، بیان نمودند که ماشین‌های بردار پشتیبان برای داده‌هایی با ابعاد بالا به‌خوبی جوابگو می‌باشد، همچنین مدلی را انتخاب می‌کند که بین میزان خطای تجربی و تقریب یک حالت بهینه را انتخاب کند.

کوکوک و بولتینک<sup>۱۱</sup> (۱۹۹۹) نشان دادند که استفاده از شبکه‌های عصبی مصنوعی برای تخمین منحنی رطوبتی خاک‌های با مواد آلی بالا و غیرآهکی نتایج بهتری از توابع انتقالی رگرسیونی مانند مدل گوپتا ولارسون<sup>۱۲</sup> (۱۹۷۹) ارائه

1-Pedotransfer functions

2- Nguyen et al

3-Boma

4- Minasny & Mcbratney

5- Botula et al

6- Linear Regression

7- Artificial Neural Networks

8- Adaptive Neuro Fuzzy Inference System

9 Support Vector Regression

10-Schaap and Leij

11-Koekkoek and Booltink

12- Gupta and Larson



# ماهنامه علمی تخصصی پایا شهر



می دهد. همچنین نمس و همکاران<sup>۱۳</sup> در سال ۲۰۰۳، عنوان نمودند که اشتقاق توابع انتقالی با استفاده از داده های کم ولی مناسب بهتر از استفاده از پایگاه داده های بزرگتر ولی عمومی و نامناسب می باشد.

آنگرو و همکاران<sup>۱۴</sup> (۲۰۰۷) با توجه به این مطلب که خصوصیات جغرافیایی و منطقه ای تنوع زیادی را در خاک ها پدید می آورد، عنوان نمودند که اعتمادپذیر بودن توابع انتقالی رابطه ای بسیار قوی با مجموعه داده هایی دارد که برای واسنجی آن ها به کار می رود. لذا خصوصاً در هنگامی که از شبکه های عصبی استفاده می شود، بررسی کارایی شبکه آموزش داده شده با پایگاه های داده عظیم موجود، برای نمونه های خاک محلی بسیار مهم می باشد. به طوری که حتی ممکن است نتایج ضعیفی از اجرای شبکه های عصبی به دست آید. از طرفی به علت اینکه شبکه های عصبی نیازمند تعداد داده های زیادی برای آموزش می باشند، کاربرد آنها در مقیاس های کوچک و سطح مزرعه صرفاً با استفاده از داده های موجود مورد سوال می باشد.

زنگ و همکاران<sup>۱۵</sup> (۲۰۰۷) منحنی رطوبتی خاک را برای تعداد ۱۱۰ نمونه خاک غیرآهکی با کلاس های بافتی مختلف به روش شبکه عصبی مصنوعی و رگرسیونی تخمین زدند و نشان دادند شبکه عصبی منحنی رطوبتی را در بیشتر کلاس های بافتی بهتر از روش رگرسیونی و با ضریب همبستگی بالاتری تخمین می زند.

نوری و همکاران<sup>۱۶</sup> (۲۰۰۸) برای کاهش متغیرهای ورودی به مدل SVM در پیش بینی میزان زباله های تولیدی در شهر مشهد از تحلیل مولفه های اصلی<sup>۱۷</sup> (PCA) استفاده نمودند و با مقایسه ی مدل ترکیبی PCA – SVM با مدل SVM برتری مدل PCA – SVM را نتیجه گرفتند.

لین و همکاران<sup>۱۸</sup> (۲۰۰۹) بیان نمودند که نتایج گویای این واقعیت است روش SVM خیلی سریع تر از شبکه عصبی مصنوعی آموزش می بیند. همچنین SVM پیش بینی دقیق تری را نسبت به شبکه عصبی مصنوعی نشان داده است. چن و همکاران<sup>۱۹</sup> (۲۰۱۰) از ماشین های بردار پشتیبان برای مدل کردن بارش روزانه استفاده کردند و نتایج را با نتایج حاصل از روش آنالیز چند متغیره مقایسه نمودند و نشان دادند نتایج پیش بینی های حاصله از SVM دقیق تر است. کاکایی لافدانی و همکاران<sup>۲۰</sup> (۲۰۱۳)، با استفاده از روش رگرسیون بردار پشتیبان و شبکه عصبی به منظور تخمین بار رسوبی رودخانه دوراج پرداختند. آنها کارایی بالای هر دو روش را گزارش نمودند.

کائوهو و همکاران<sup>۲۱</sup> (۲۰۱۴) با استفاده از ماشین های بردار پشتیبان، به پیش بینی ظرفیت کاتیونی در افق های مختلف خاک در شهر چینگدائو چین پرداختند. آنها بررسی های خود را در ۲۰۸ نقطه و در دو افق خاک انجام دادند و در پایان بیان نمودند که مدل SVM پیش بینی ها را بهبود می بخشد.

با توجه به اهمیت آگاهی از نقاط مهم منحنی مشخصه خاک در منطقه شاهرود برای طرح های کشاورزی و برنامه ریزی های آبیاری و دشواری اندازه گیری مستقیم آن ها، توسعه توابع انتقالی مناسب و یا ارزیابی مدل ها در به دست آوردن رطوبت ظرفیت زراعی و نقطه پژمردگی دائم در این منطقه لازم می باشد. بنابراین در این تحقیق، عملکرد مدل رگرسیون بردار پشتیبان در توسعه توابع انتقالی خاک و اثر تعداد و نوع متغیرهای ورودی بر عملکرد مدل های مورد استفاده برای استخراج توابع انتقالی مورد ارزیابی قرار گرفته است.

## مواد و روش ها

13- Nemes *et al*

14-Ungaro *et al*

15- Zhang *et al*

16- Noori *et al*

17- Principal Component Analysis (PCA)

18- Lin *et al*

19- Chen *et al*

20- Kakaie lafdani *et al*

21- Kaihua *et al*



## ماهنامه علمی تخصصی پایا شهر

در این تحقیق از داده‌های زود یافت شامل بافت خاک (درصد رس، شن و سیلت)، چگالی ظاهری و مواد آلی و داده‌های دیریافت شامل ظرفیت زراعی و نقطه پژمردگی دائم، مربوط به مطالعات خاکشناسی شهرستان شاهرود موجود در مرکز تحقیقات و آموزش کشاورزی استان سمنان استفاده شده‌است. داده‌ها از ۱۰۰ نمونه پروفیل از مناطق مختلف شهرستان شاهرود جمع آوری شده است.

اولین گام برای توسعه توابع انتقالی، ارائه روابط تجربی میان خصوصیات پایه خاک و عواملی است که باید پیش‌بینی شوند. این امر می‌تواند به وسیله روش‌های مختلف ریاضی (مانند رگرسیون بردار پشتیبان و شبکه‌های عصبی مصنوعی) محقق شود. در ادامه توضیح مختصری در مورد روش مورد استفاده در این پژوهش ارائه می‌گردد:

### رگرسیون خطی چند متغیره<sup>۲۲</sup>

در روش رگرسیون خطی چند متغیره (MLR)، مقادیر متغیر خروجی بر اساس داده‌های ورودی و خطوط تصمیم‌گیری پیش‌بینی می‌شوند. در واقع تکنیک رگرسیون، مجموعه‌ای از داده‌های آزمایشی را دریافت نموده و فرمولی را به آن داده‌ها برازش می‌نماید. رگرسیون می‌تواند برای حل مسائل کلاس‌بندی و نیز برای پیش‌گویی مورد استفاده قرار بگیرد. روش رگرسیون خطی، یک تکنیک یادگیری نظارتی است که به وسیله آن تغییرات یک متغیر وابسته به وسیله ترکیب خطی از یک یا چند متغیر مستقل مدل می‌گردد. حالت کلی معادله مدل رگرسیون خطی به صورت رابطه ۱ بیان می‌گردد:

$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p \quad (1)$$

که در این رابطه،  $X_i$  ها متغیرهای مستقل و  $\beta_i$  ها ضرایب ثابت و  $Y$  متغیر وابسته می‌باشند (اسدی و همکاران، ۱۳۹۳).

### شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) ابزار ریاضی قدرتمندی هستند که با تقلید ساده از سیستم عصبی بیولوژیک ساخته شده‌اند و قدرت انعطاف و تصحیح‌پذیری بالایی در انطباق با داده‌های موجود دارند. مهم‌ترین موضوع در این مدل‌ها، انتخاب ورودی‌های مناسب به مدل برای رسیدن به خروجی‌های مد نظر می‌باشد. علاوه بر آن ساختار شبکه‌های عصبی مصنوعی و نحوه انتخاب ارتباط بین نرون‌ها و وزنی که هر نرون به خود اختصاص خواهد داد از اهمیت بالایی برخوردار است. ساختار یک شبکه عصبی متشکل از تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، نحوه ارتباط لایه‌ها با هم، روش آموزش شبکه و نحوه توزیع پارامترها می‌باشد.

شکل (۱) ساختار ساده یک شبکه عصبی پرسپترون را نشان می‌دهد. هر نرون توسط لایه‌ی خروجی‌اش به نرون‌های لایه بعد متصل است ولی با نرون‌های لایه‌ی خودش ارتباط ندارد (اسچاپ و لچی، ۱۹۹۸).

### توابع انتقالی بر پایه ماشین‌های بردار پشتیبان

ساختار مدل ماشین‌های بردار پشتیبان (SVM) توسط وپنیک که یک ریاضیدان روسی در دهه ۱۹۶۰ بود، ارائه شد. مدل‌های SVM که بر پایه‌ی تئوری آموزش احتمال قرار دارند، یک کلاس جدید از مدل‌هایی هستند که به منظور طبقه‌بندی و پیش‌بینی در علوم مختلف استفاده می‌شوند (وپنیک<sup>۲۳</sup>، ۱۹۹۵). اخیراً این مدل‌ها در یک گستره وسیع از مسائل هیدرولوژیکی مورد استفاده قرار گرفته‌اند. مشابه با هر مدل ریاضی و آماری، مدل‌های SVM نیز دارای معایبی هستند.

22-Multivariate linear regression

23-Vapnik



وجود تعداد زیاد متغیر ورودی اصلی‌ترین مشکل در توسعه این مدل‌هاست. تعداد زیاد متغیرهای ورودی ممکن است مانع یافتن مدل بهینه توسط SVM شود. راه‌های متعددی برای کاهش تعداد متغیرهای ورودی پیشنهاد شده است که از آن جمله می‌توان به روش تحلیل مؤلفه‌های اصلی اشاره نمود (زنگ، ۲۰۰۷).

ویژگی مهم ماشین بردار پشتیبان این است که برخلاف الگوریتم‌های کلاسیک و رگرسیون‌های خطی که به وسیله حداقل کردن قدرمطلق خطا یا توان دوم خطا عمل می‌کنند، ریسک عملیاتی را حداقل می‌کنند. ماشین بردار پشتیبان برخلاف شبکه‌های عصبی با مشکل گیر افتادن در حداقل‌های محل تابع خطا مواجه نمی‌باشد (هونگ و همکاران<sup>۲۴</sup>، ۲۰۱۱ و یان و همکاران<sup>۲۵</sup>، ۲۰۱۱). شکل (۱) ساختار ماشین بردار پشتیبان را نشان می‌دهد (یوون و همکاران<sup>۲۶</sup>، ۲۰۱۱). شکل (۲) ساختار ماشین بردار پشتیبان را نشان می‌دهد.

## توابع کرنل

استفاده از توابع کرنل باعث می‌شود به جای آن‌که در حوزه ورودی‌ها کار کنیم به فضای دیگری منتقل شده و در آن فضای مجازی داده‌ها را دسته‌بندی کنیم. استفاده از تابع کرنل در حوزه ورودی معادل با ضرب داخلی در فضای مجازی است (ونگ<sup>۲۷</sup>، ۲۰۰۵).

اگر  $k$  تابعی باشد که در شرایط مرسر<sup>۲۸</sup> صادق باشد یعنی شرط زیر را برآورد کند:

$$K(x, \hat{x}) = \sum_m^{\infty} a_m \phi_m(x) \phi_m(\hat{x}), \quad a_m \geq 0 \quad (2)$$

$$\iint K(x, \hat{x}) g(x) g(\hat{x}) dx d\hat{x} > 0 \quad g \in L_2 \quad (3)$$

آنگاه کرنل، یک ضرب داخلی درست را در فضای مجازی نشان می‌دهد. توابعی که شرایط مرسر را ارضا می‌کنند در زیر آمده‌اند.

## کرنل چند جمله‌ای<sup>۲۹</sup>

کرنل غیرخطی یک کرنل مورد توجه برای مدل‌های غیرخطی می‌باشد.

$$K(x, \hat{x}) = ((x, \hat{x}) + 1)^d \quad (4)$$

اصلی‌ترین ویژگی ماشین‌های بردار پشتیبان استفاده از کرنل‌ها، عدم وجود نقطه کمینه محلی، پراکندگی جواب‌ها و کنترل ظرفیت بدست آمده از طریق بهبود حواشی است.

## روش پژوهش با کمک رگرسیون بردار پشتیبان

جهت دست‌یافتن به بهترین عملکرد روش‌های به کار رفته در این تحقیق پنج ترکیب متفاوت (مدل مختلف) از ورودی‌ها در نظر گرفته شد. برای هر کدام از مدل‌ها، بهترین مدل از هر نوع با توجه به معیارهای ارزیابی ذکر شده و نتایج بدست‌آمده انتخاب شد. جهت انجام عملیات یادگیری و استفاده از رگرسیون بردار پشتیبان در برآورد نقاط مهم رطوبتی از نرم



# ماهنامه علمی تخصصی پایا شهر



افزار LibSVM استفاده شد. این نرم افزار دو حالت کلی برای حل مسأله رگرسیونی دارد (epsilon-SVR و nu-SVR)، که تفاوت آنها در چگونگی بیان مسأله به صورت یک مسأله بهینه‌سازی و همچنین پارامتر مورد تنظیم است. در این پژوهش یک روش برای توابع کرنل خطی، یعنی تابع شعاعی (RBF) مورد بررسی قرار گرفت.

## نتایج و بحث


در تحقیق حاضر، داده‌های موجود به دودسته داده‌های آموزش و داده‌های آزمون تقسیم شدند. آموزش مدل به‌وسیله ۸۰ درصد داده‌ها، انجام شد و عملکرد روش‌ها با استفاده از ۲۰ درصد داده‌های باقی‌مانده ارزیابی گردید. برای مقایسه مقادیر اندازه‌گیری شده با مقادیر پیش‌بینی شده از شاخص‌های کمی ریشه میانگین مربعات خطا نرمال شده یا NRMSE<sup>۳</sup> (رابطه ۵)، ضریب تعیین یا R<sup>۲</sup> (رابطه ۶) و میانگین جذر مجموع مجذور انحرافات خطا یا MSD (رابطه ۷) استفاده گردید. مقادیر ضریب تعیین و ضریب کارایی نش هرچه به عدد یک نزدیکتر باشد، عملکرد و صحت مدل بالاتر خواهد بود. مقدار NRMSE بین صفر و یک است که می‌توان آن را به صورت درصد نیز بیان نمود و هر چه مقدار آن کمتر باشد صحت تخمین بهتری خواهد داشت. به‌طور کلی مقادیر کمتر از ۱۰ درصد صحت تخمین ایده‌آل در مدل‌سازی دارند. مقادیر بین ۱۰ تا ۲۰ و ۲۰ تا ۳۰ درصد به ترتیب صحت تخمین خوب و متوسط و مقادیر بالای ۳۰ درصد فاقد اعتبار لازم در مدل‌سازی را داراست (شیرانی، ۱۳۹۱، جعفری‌گیلانده و همکاران ۱۳۹۵).

$$NRMSE = \left( \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i - M_i)^2} \right) \times \left( \frac{100}{\bar{M}} \right) \quad (5)$$

$$R^2 = \frac{\left( \sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P}) \right)^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \cdot \sum_{i=1}^n (P_i - \bar{P})^2} \quad (6)$$

$$MSD = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (7)$$

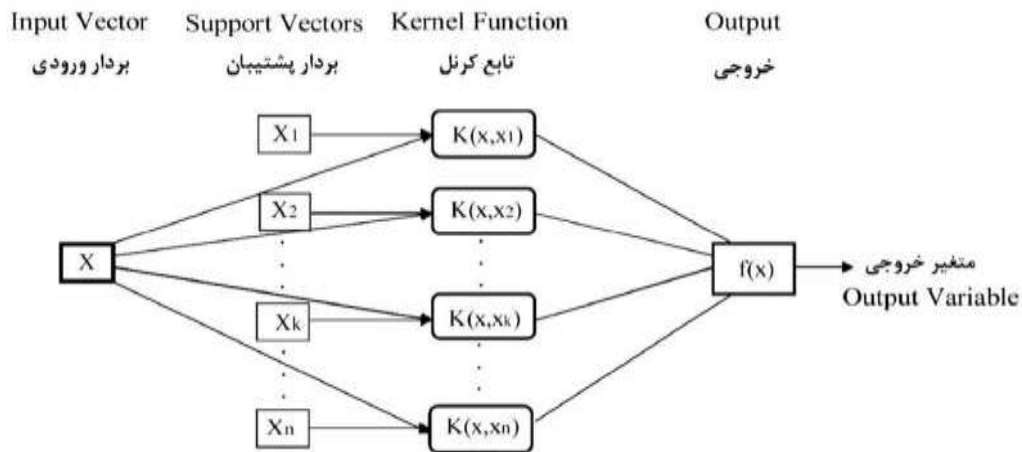
در روابط فوق  $O_i$  و  $P_i$  به ترتیب مقادیر مشاهداتی و پیش‌بینی شده در نمونه  $i$  ام،  $n$  تعداد نمونه‌ها و  $\bar{O}$  و  $\bar{P}$  میانگین مقادیر مشاهداتی و پیش‌بینی شده هستند.



شکل شماره (۱): شماتیک یک مدل شبکه عصبی چند لایه (لایه ورودی، لایه میانی ولایه خروجی) ارزیابی روش‌های مورد استفاده



# ماهنامه علمی تخصصی پایا شهر



شکل شماره (۲) : ساختار ماشین بردار پشتیبان

مشخصات آماری داده‌های مورد استفاده در جدول شماره (۱) ارائه شده است. به منظور دستیابی به مدل‌های با صحت بیشتر، برای نرمالسازی داده‌ها از روش صفرویک استفاده شد.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (۸)$$

که در این فرمول  $X_{norm}$  مقادیر نرمال شده،  $X$  مقدار مشاهده شد،  $X_{max}$  و  $X_{min}$  به ترتیب مقدار بیشینه و کمینه مشاهده شده است.

در ادامه براساس تحلیل همبستگی از بین متغیرهای درصد شن (Sand)، درصد رس (Clay)، درصد سیلت (Silt)، چگالی ظاهری خاک (bd) و درصد کربن آلی خاک (OC)، پنج ترکیب متفاوت برای متغیرهای ورودی جهت تخمین نقاط مهم رطوبتی انتخاب شد که در جدول (۲) ارائه شده است.

جدول (۱)-داده‌های مورد استفاده برای ظرفیت زراعی و نقطه پژمردگی دائم

(۱۰۰ = تعداد)							
پارامتر	Sand	Clay	Silt	bd	OC	FC	PWP
حداکثر	۸۹	۳۴	۵۸	۱/۷۹	۲/۰۶	۳۳/۰۲	۲۱/۱۷
حداقل	۱۸	۴	۷	۱/۳۹	-۰/۱۳	۶/۵۴	۵/۸۹
میانگین	۴۳	۱۸	۳۷	۱/۵۴	-۰/۷۲	۲۳/۰۷	۱۰/۱۱
انحراف معیار	۱۶/۹۳	۵/۸۳	۱۴/۳۴	-۰/۰۸	-۰/۴۴	۵/۵۴	۲/۶۴
کشیدگی	-۰/۲۰	۰/۳۰	-۰/۸۵	-۰/۸۴	۰/۹۹	۰/۳۶	۴/۴۹
چولگی	-۰/۵۹	۰/۱۸	-۰/۴۹	۰/۱۷	۱/۰۴	-۰/۴۷	۱/۷۸
مد	۳۶	۱۶	۵۴	۱/۵۱	-۰/۳۶	۲۰/۱۲	۸/۷۷



جدول ۲: سناریوهای تعریف شده

Sand- Silt- Clay- bd- OC	سناریو شماره ۱
Sand- Silt- Clay- bd	سناریو شماره ۲
Sand- Silt- Clay	سناریو شماره ۳
Sand- Silt	سناریو شماره ۴
Silt	سناریو شماره ۵

### نتایج مدل‌سازی رگرسیون چندمتغیره

مدل رگرسیون خطی چندمتغیره با استفاده از نرم افزار SPSS به هرکدام از مدل‌های ذکر شده در دو نقطه‌ی رطوبتی مورد نظر برازش داده شد. رابطه‌ی رگرسیونی به دست آمده برای هر مدل با استفاده از داده‌های آزمون مورد ارزیابی قرار گرفت و معیارهای ارزیابی برای آن محاسبه گردید. نتایج به دست آمده از ارزیابی روش رگرسیون خطی چند متغیره در جدول شماره (۳) ارائه شده است.

با توجه به نتایج جدول (۳) مشاهده می‌شود مدل رگرسیون در سناریو اول بهترین عملکرد را از نظر بالا بودن ضریب تعیین و پایین بودن میزان خطا و  $NRMSE$  به ترتیب با مقادیر  $0/50$ ،  $4/53$  و  $18/67$  برای ظرفیت زراعی و  $0/45$ ،  $25/63$  و  $2/73$  برای نقطه پژمردگی دائم داراست. به‌طور کلی از نظر معیار  $NRMSE$  تمام مدل‌ها برای ظرفیت زراعی خوب یا متوسط و برای نقطه پژمردگی دائم در سطح متوسط و ضعیف قرار گرفته‌اند

جدول ۳- نتایج آزمون مدل‌سازی به‌وسیله رگرسیون خطی چندمتغیره

سناریو	FC			PWP		
	$R^2$	NRMSE	MSD	$R^2$	NRMSE	MSD
۱	0/50	18/67	4/53	0/45	25/63	2/73
۲	0/49	19/72	4/78	0/27	28/25	3/01
۳	0/43	20/57	4/99	0/18	29/55	3/15
۴	0/28	22/67	5/50	0/16	32/00	3/41
۵	0/11	24/89	6/03	0/20	29/52	3/14

### نتایج شبکه عصبی

به منظور دسترسی به بهترین معماری مدل شبکه عصبی مصنوعی در پیش‌بینی توابع انتقالی، توابع محرک و الگوریتم‌های آموزش مختلف در تعداد نوروهای متفاوت (بین ۲ تا ۱۰) مورد بررسی قرار گرفتند. بهترین معماری مدل شبکه عصبی پرسپترون چند لایه طی فرآیند سعی و خطا برای هر کدام از ترکیب‌های ورودی در هر دو نقطه‌ی رطوبتی به دست آمد. نتایج به دست آمده برای مدل شبکه عصبی در جداول (۴ و ۵) ارائه شده است.





شانزدهمین کنفرانس ملی مهندسی عمران، معماری و شهرسازی

جدول ۴- نتایج شبکه عصبی برای ظرفیت زراعی در مدل های مختلف

سناریو	تعداد نورون	آموزش		صحت سنجی		آزمون		MSD
		$R^2$	NRMSE	$R^2$	NRMSE	$R^2$	NRMSE	
۱	۸	۰/۸۳	۴/۱۱	۰/۸۲	۷/۱۷	۰/۷۲	۱۴/۳۶	۳/۴۸
۲	۳	۰/۷۹	۵/۸۰	۰/۸۰	۷/۷۴	۰/۷۱	۱۵/۶۴	۳/۷۹
۳	۵	۰/۷۱	۷/۰۰	۰/۶۸	۹/۰۵	۰/۶۷	۱۶/۳۲	۳/۹۶
۴	۲	۰/۶۶	۷/۸۶	۰/۶۶	۹/۱۶	۰/۶۳	۱۷/۶۱	۴/۲۷
۵	۹	۰/۶۰	۸/۶۳	۰/۶۳	۹/۴۳	۰/۶۰	۱۸/۶۲	۴/۵۱

جدول ۵- نتایج شبکه عصبی برای نقطه پژمردگی دائم در مدل های مختلف

سناریو	تعداد نورون	آموزش		صحت سنجی		آزمون		MSD
		$R^2$	NRMSE	$R^2$	NRMSE	$R^2$	NRMSE	
۱	۸	۰/۷۸	۱۱/۸۴	۱/۸۶	۹/۱۲	۰/۷۵	۱۷/۹۱	۱/۹۰
۲	۵	۰/۷۵	۱۲/۵۴	۱/۸۱	۱۳/۳۶	۰/۷۴	۱۸/۶۹	۱/۹۹
۳	۶	۰/۷۱	۱۴/۷۵	۱/۷۲	۱۶/۵۲	۰/۵۷	۲۲/۲۶	۲/۳۷
۴	۸	۰/۶۹	۱۵/۰۸	۱/۷۰	۱۸/۲۲	۰/۴۷	۲۶/۹۹	۲/۸۶
۵	۲	۰/۵۹	۱۷/۷۰	۱/۴۶	۲۳/۲۱	۰/۲۶	۲۸/۰۵	۳/۰۰

با توجه به جداول شماره (۴ و ۵) مشاهده می شود که همانند روش رگرسیونی هرچه از ورودی های بیشتری استفاده شود نتایج بهتری حاصل می شود. در بهترین حالت مقادیر ضریب تعیین، میانگین جذر مجموع مجذور انحرافات خطا و ریشه میانگین مربعات خطا نرمال شده به ترتیب برابر با ۰/۷۲ ، ۳/۴۸ و ۱۴/۳۶ برای ظرفیت زراعی و ۰/۷۵ ، ۱/۹۰ و ۱۷/۹۱ برای نقطه پژمردگی، بیانگر ارتقاء مدل ها و توانایی بالای روش شبکه های عصبی مصنوعی در پیش بینی نقاط مهم رطوبتی است. علاوه بر آن، مدل ها برای ظرفیت زراعی از سطح متوسط به سطح خوب و برای نقطه پژمردگی دائم از سطح ضعیف یا متوسط به سطح خوب یا متوسط ارتقاء پیدا کرده اند.

نتایج مدلسازی رگرسیون بردار پشتیبان (SVR)

نتایج به دست آمده برای مدل سازی ظرفیت زراعی با روش رگرسیون بردار پشتیبان در جداول (۶) ارائه شده است. با توجه به جدول شماره (۶) مشاهده می شود که در بهترین حالت مقادیر ضریب تعیین، میانگین جذر مجموع مجذور انحرافات خطا و ریشه میانگین مربعات خطا نرمال شده به ترتیب برابر با ۰/۸۵ ، ۳/۱۲ و ۱۲/۸۹ برای ظرفیت زراعی و ۰/۸۳ ، ۱/۵۸ و ۱۴/۸۴ برای نقطه پژمردگی، بیانگر دقت بالای مدل های حاصل از روش رگرسیون بردار پشتیبان در پیش بینی نقاط مهم رطوبتی است، گرچه تفاوت آن قابل توجه نیست. تمامی مدل های حاصله از رگرسیون بردار پشتیبان برای ظرفیت زراعی و سناریوهای یک تا چهار برای نقطه پژمردگی دائم در سطح خوب قرار دارند و ارزیابی مدل ها قابل قبول است.



جدول ۶- نتایج SVR در سناریوهای مختلف

سناریو	ظرفیت زراعی			نقطه پژمردگی دائم						
	آموزش	آزمون	آزمون	آموزش	آزمون	آزمون				
	$R^2$	MSD	$R^2$	NRMSE	MSD	$R^2$	MSD	$R^2$	NRMSE	MSD
۱	۰/۸۹	۲/۱۲	۰/۸۵	۱۲/۸۹	۳/۱۲	۰/۹۲	۰/۹۷	۰/۸۳	۱۴/۸۴	۱/۵۸
۲	۰/۸۹	۲/۱۸	۰/۸۳	۱۳/۴۹	۳/۲۷	۰/۹۰	۱/۱۲	۰/۷۸	۱۶/۰۱	۱/۷۰
۳	۰/۸۵	۲/۵۱	۰/۸۳	۱۳/۷۲	۳/۳۳	۰/۸۶	۱/۴۲	۰/۷۴	۱۶/۷۴	۱/۷۸
۴	۰/۸۴	۲/۹۸	۰/۷۹	۱۵/۳۰	۳/۷۱	۰/۸۶	۱/۶۳	۰/۷۴	۱۶/۹۵	۱/۸۰
۵	۰/۸۱	۳/۰۸	۰/۷۲	۱۶/۲۱	۳/۹۴	۰/۸۰	۱/۹۷	۰/۷۲	۲۰/۶۳	۲/۲۰

### نتیجه‌گیری و پیشنهادات

روش‌های داده مبناء می‌توانند با عملکرد نسبتاً مناسبی نقاط مهم رطوبتی شامل ظرفیت زراعی و نقطه پژمردگی دائم را برآورد کنند. در این تحقیق عملکرد مدل شبکه عصبی در مقایسه با روش سنتی رگرسیون آماری با توجه به معیارهای ارزیابی ذکر شده، به مراتب بهتر بوده است. این نتیجه با نتایج پژوهش‌های معلمی و دوات‌گر (۱۳۹۰)، اسچاپ و همکاران (۱۹۹۸)، اسچاپ و لچی (۱۹۹۸)، زنگ و همکاران (۲۰۰۷)، باکر و همکاران<sup>۱</sup> (۲۰۰۸) که از برتری شبکه عصبی در مقایسه با رگرسیون خطی گزارش داده بودند، مطابقت دارد. اما در مقایسه عملکرد مدل‌های حاصله از روش شبکه عصبی با روش رگرسیون بردار پشتیبان، مشهود است که روش رگرسیون بردار پشتیبان عملکرد بهتری داشته است. مقادیر بالاتر ضریب تعیین در سناریوهای حاصله از این روش نشان از صحت و کارایی بالاتر این مدل در برآورد نقاط مهم رطوبتی داشته است. همچنین می‌توان بیان نمود که روش رگرسیون بردار پشتیبان در مقایسه با روش‌هایی همچون شبکه عصبی و روش رگرسیون آماری، نتایج را بهبود می‌دهد. این نتیجه با گزارش‌های حاصله از محققانی همچون نوری و همکاران (۲۰۱۱)، کیسی و سیمن (۲۰۱۱)، کاکایی لعدانی و همکاران (۲۰۱۳) و کائوهو و همکاران (۲۰۱۴) برابری می‌کند.

با توجه به اینکه کارایی مدل رگرسیون بردار پشتیبان در کاربردهای مختلفی توسط پژوهشگران متعدد به اثبات رسیده است، استفاده از این روش برای ایجاد توابع انتقالی خاک در مناطق مختلف توصیه می‌شود، همچنین استفاده از پارامترهای بیشتر باعث آموزش بهتر مدل‌ها خواهد شد، در ادامه پیشنهاد می‌گردد برای آموزش بهتر مدل‌ها از پایگاه داده وسیع‌تری با دقت بالا در اندازه‌گیری مقادیر و همچنین دارای همبستگی اولیه بالا استفاده شود. در تحقیق حاضر، داده‌های مورد استفاده از مرکز تحقیقات کشاورزی استان سمنان و با تعداد محدودی دریافت شده در صورتی که در کشورهای توسعه یافته چنین مطالعاتی با توجه به داشتن داده‌های فراوان و موجود در پایگاه داده‌هایی مانند UNSPDA (پایگاه داده‌های خاک‌های ایالات متحده آمریکا) و HYPRES (پایگاه داده‌های خاک‌های اروپا) صورت می‌گیرد و داده‌های مربوط به خصوصیات خاک برای مناطق خشک و نیمه‌خشک مانند ایران لازم و ضروری می‌باشد.

### سپاسگزاری

این مقاله با همکاری مدیریت برنامه‌ریزی موسسه پایدارسازان، مهندس مهدی مقدم و مهندس مهدی حاجی‌هاشمی و ریاست محترم کارگاه راه آهن چابهار زاهدان مهندس علی باقری روشنی تهیه شده که از ایشان کمال تشکر و قدردانی را داریم.