

## پیش‌بینی مقاومت به کشش یک تیغه باریک خاک‌ورز عمودی با استفاده از شبکه عصبی مصنوعی

یوسف عباسپور گیلانده<sup>1\*</sup>، حمید جلیل‌نژاد<sup>2</sup>، ترحم مصری گندشمین<sup>3</sup>

تاریخ دریافت: 91/12/29

تاریخ پذیرش: 92/6/1

- 1- گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی
  - 2- گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی
  - 3- گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشکده فناوری کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی
- \*مسئول مکاتبه: E-mail: [abbaspour@uma.ac.ir](mailto:abbaspour@uma.ac.ir)

### چکیده

مقاومت به کشش ابزارهای مختلف خاک‌ورزی یک پارامتر مهم برای اندازه‌گیری و ارزیابی عملکرد ادوات برای تعیین میزان انرژی مورد نیاز می‌باشد. پیش‌بینی این پارامتر می‌تواند در بسیاری از اهداف مدیریتی نیز، از جمله انتخاب تراکتور مناسب، موثر واقع گردد. در این تحقیق آزمایش‌های مزرعه‌ای در دو نوع خاک لومی‌رسی و رسی لومی به‌منظور پیش‌بینی مقاومت به کشش با استفاده از شبکه عصبی مصنوعی با داشتن برخی پارامترهای نوع و شرایط خاک، پارامترهای ابزار و پارامترهای عملیاتی و مقایسه دقت مدل بدست آمده با مدل‌های رگرسیونی انجام گردید. آزمایشات در داخل هر بافت خاک در قالب آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCBD) و با سه تکرار انجام شد. در داخل هر بافت خاک سطوح مختلف رطوبت از 5 تا 16 درصد برای خاک‌های خشک و 17 تا 38 درصد برای خاک‌های مرطوب، سرعت پیشروی تراکتور در چهار سطح 1، 1/5 و 1/8 و 3 کیلومتر در ساعت، عمق کار در چهار سطح 10، 20، 30 و 40 سانتی‌متر و عرض تیغه نیز در چهار سطح 2/5، 3، 3/5 و 4 سانتی‌متر انتخاب، و در داخل هر کرت آزمایشی مشخصه‌های نیروی مقاوم کششی، شاخص مخروطی خاک و درصد محتوی رطوبتی خاک اندازه‌گیری شدند. شبکه‌های طراحی شده در این تحقیق که به‌منظور پیش‌بینی مقاومت به کشش ابزار باریک خاک‌ورز عمودی مورد استفاده قرار گرفتند، از نوع شبکه‌های چندلایه پس انتشار برگشتی بودند. از سه روش الگوریتم گرادیان نزولی با مومنتوم، الگوریتم لوبنبرگ - مارکوات و الگوریتم گرادیان نزولی مزدوج مقیاسی به‌منظور آموزش شبکه استفاده گردید. نتایج این تحقیق نشان داد که شبکه عصبی توسعه داده شده با الگوریتم لوبنبرگ - مارکوات در مقایسه با سایر الگوریتم‌ها عملکرد بهتری دارد. میانگین دقت شبیه‌سازی 95/05 درصد و ضریب همبستگی 0/9935 برای مدل توسعه داده شده در این تحقیق بدست آمد. داده‌های بدست آمده از مدل شبکه عصبی مصنوعی با مدل‌های ASAE و مدل اشرفی‌زاده (2006) مقایسه شدند. نتیجه این مقایسه نشان داد که داده‌های پیش‌بینی شده توسط شبکه عصبی مصنوعی خیلی نزدیک به داده‌های واقعی بدست آمده از آزمایشات مزرعه‌ای می‌باشند و مدل‌های رگرسیونی نتوانستند کاربرد چندانی برای پیش‌بینی مقاومت به کشش در خاک‌های مورد مطالعه داشته باشند.

واژه‌های کلیدی: مقاومت به کشش، تیغه باریک خاک‌ورز عمودی، شبکه عصبی مصنوعی، الگوریتم آموزشی لوبنبرگ - مارکوات.

## 1- مقدمه

نیروی مقاوم کششی مورد نیاز یک وسیله خاک‌ورز باریک عمودی توسط شبکه عصبی مصنوعی با مدل‌های رگرسیونی موجود می‌باشد.

## 2- مواد و روش‌ها

## 2-1- ادوات مورد استفاده در انجام تحقیق

از یک دستگاه نفوذسنج مخروطی پشت تراکتوری سوار (شکل 1) به منظور اندازه‌گیری مقادیر شاخص مخروطی خاک استفاده گردید (عباسپور گیلانده و همکاران، 1389 ب). دستگاه نفوذسنج به اتصال سه‌نقطه یک تراکتور تک دیفرانسیل مسی فرگوسن مدل MF-285 نصب شده و راننده این تراکتور می‌توانست نفوذسنج را به کار انداخته و کنترل نماید. مقادیر شاخص مخروطی براساس نیروی اندازه‌گیری شده برای فشار دادن یک مخروط با سطح مقطع 133 میلی‌متر مربع و زاویه نوک 30 درجه به داخل خاک محاسبه گردید. به منظور اندازه‌گیری عمق نفوذ از حسگر سنسج جابجایی مدل DP-5000 ساخت شرکت Tokyo sokki-kenkyujo، با دقت  $20 \times 10^{-6}$  mm استفاده شده است که قادر به اندازه‌گیری عمق تا 50 سانتی‌متر به صورت پیوسته می‌باشد. سامانه جمع‌آوری داده شامل یک دیتالاگر مدل DT800، ساخت شرکت DataTaker با قابلیت برنامه‌نویسی و یک کامپیوتر کیفی در داخل کابین راننده می‌باشد.



شکل 1- نفوذسنج مخروطی پشت تراکتوری

از یک تراکتور مسی فرگوسن مدل MF-285 تک دیفرانسیل 75 اسب بخار و مجهز به سامانه ابزار اندازه‌گیری دقیق به منظور جمع‌آوری داده‌های مقاومت به کشش، سرعت پیشروی و بار دینامیکی وارد بر چرخ‌های جلو در جریان انجام عملیات خاک‌ورزی استفاده گردید. سامانه اندازه‌گیری دقیق تراکتور مجهز به دینامومتر اتصال سه‌نقطه، حسگر اندازه‌گیری سرعت از نوع چرخ پنجم، حسگر اندازه‌گیری بار دینامیکی (کرنش‌سنج‌های نصب شده بر روی محور جلوی تراکتور) و سیستم جمع‌آوری داده می‌باشد (شکل 2).

مقاومت به کشش یکی از مهمترین نیروهای بین تراکتور و ادوات محسوب می‌گردد و نقش اساسی در مدیریت تراکتور و ادوات کشاورزی ایفا می‌کند. مهندسان ماشین‌های کشاورزی با در دست داشتن داده‌های مقاومت به کشش و پیش‌بینی آن در شرایط زراعی می‌توانند تراکتور و ادوات مناسب را با کمترین هدررفت انرژی انتخاب کنند. مقاومت به کشش ادوات خاک‌ورزی یکی از مهمترین نیروهای است که برای اندازه‌گیری و ارزیابی انرژی مورد نیاز ادوات کشاورزی مورد استفاده قرار می‌گیرد. این نیرو تابعی از پارامترهای شرایط خاک (از قبیل محتوی رطوبتی، بافت خاک و ...)، پارامترهای ابزار (از قبیل عمق، زاویه حمله، تیزی تیغه و ...) و پارامترهای عملیاتی (از قبیل سرعت پیشروی ابزار) می‌باشد که تحت شرایط مختلف تغییر می‌کند. برای محاسبه و پیش‌بینی مقاومت به کشش باید ارتباط بین این پارامترها مشخص شوند.

محققان اندکی شبکه عصبی مصنوعی (ANNs) را به منظور پیش‌بینی مقاومت به کشش ادوات خاک‌ورزی بکار برده‌اند. تحقیقی توسط علمبردانی و همکاران (2009) به منظور توسعه مدل پیش‌بینی مقاومت به کشش و انرژی مورد نیاز عملیات زیرشکنی انجام شده است. مقایسه نتایج بدست آمده از مدل شبکه عصبی مصنوعی و مدل‌های رگرسیونی نشان داد که مدل شبکه عصبی مصنوعی داده‌های بسیار نزدیک‌تری نسبت به داده‌های واقعی در مقایسه با سایر مدل‌های رگرسیونی ارائه می‌کند.

ژانگ و کوشواها (1999) یک شبکه عصبی تابع شعاعی را به منظور پیش‌بینی مقاومت به کشش تیغه‌های باریک با استفاده از سرعت، نوع ابزار و خاک به عنوان پارامترهای ورودی توسعه دادند. آنها گزارش کردند که مدل توسعه یافته برای پیش‌بینی، توانایی تعمیم خوبی در درون‌یابی در محدوده پارامترهای ورودی دارد.

کوشواها و همکاران (1998) استراتژی دیگری را ارائه نمودند که مبتنی بر ترکیب روش‌های اجزاء محدود و شبکه عصبی مصنوعی به منظور طراحی کامپیوتری ادوات خاک‌ورزی بود. در این روش ترکیبی، شبکه عصبی مصنوعی به منظور پیش‌بینی خصوصیات دینامیکی خاک، بدون نیاز به تجزیه و تحلیل تنش و کرنش در داخل خاک بکار می‌رود، و روش اجزاء محدود محاسبه نیروی کششی، تنش‌ها و جابجایی را در داخل خاک محاسبه می‌نماید. محققان دیگری نیز از جمله چوی و همکاران (2000)، الجنوبی و همکاران (2001)، مانوا و ادمنون (2007) و رنول و همکاران (2009)، شبکه عصبی مصنوعی را برای پیش‌بینی مقاومت به کشش ادوات خاک‌ورزی بکار بردند.

هدف از این تحقیق پیش‌بینی مقاومت به کشش یک وسیله خاک‌ورز باریک عمودی با استفاده از شبکه‌ی عصبی مصنوعی با داشتن برخی پارامترهای نوع و شرایط خاک، پارامترهای ابزار و پارامترهای عملیاتی، و همچنین مقایسه دقت مدل بدست آمده به منظور پیش‌بینی

جدول 1- شاخص‌های کمی ارزیابی شبکه‌های ساخته شده با استفاده از الگوریتم آموزشی لوبنرگ-مارکوات

نرون	پارامترهای شبکه		ضرایب تبیین شبکه		پارامترهای آماری شبکه		میانگین دقت شبیه‌سازی (%)	ضریب همبستگی
	MC	LR	آموزش	ارزیابی	SSE	MSE		
3	0/3	0/3	0/99347	0/9266	4/63	0/0121	94/62	0/9883
4	0/3	0/3	0/99362	0/97276	4/30	0/0112	95/2	0/9934
5	0/3	0/3	0/99346	0/9171	4/44	0/0116	94/21	0/9896
6	0/3	0/3	0/9944	0/97283	3/73	0/00972	94/56	0/9935
7	0/3	0/3	0/99379	0/90237	-	0/217	83/99	0/9053
8	0/3	0/3	0/99424	0/97458	4/01	0/0104	95/05	0/9935
9	0/3	0/3	0/9951	0/95786	3/41	0/00889	93/78	0/9914
10	0/3	0/3	0/9946	0/79955	4/53	0/0118	92/28	0/9851
11	0/3	0/3	0/9947	0/85264	3/67	0/00957	82/68	0/9698
12	0/3	0/3	0/99296	0/78209	5/28	0/0138	71/32	0/9461

جدول 2- مقایسه داده‌های بدست آمده برای مقاومت به کشش تیغه باریک خاک‌ورز عمودی توسط شبکه مدل عصبی مصنوعی با داده‌های مدل‌های رگرسیونی برای خاک رسی لومی

مقادیر مقاومت به کشش برای یک تیغه باریک خاک‌ورز در عمق مشخص (kN)					منابع داده
40cm	30cm	20cm	10cm		
0/24	0/18	0/12	0/06	خاک با بافت سنگین	استاندارد ASAE
11/91	6/65	5/56	2/57	شرایط مرطوب	داده‌های بدست آمده از آزمایش‌های مزرعه‌ای
13/1	11/47	6/65	4/1	شرایط خشک	
11/87	6/58	5/34	2/08	شرایط مرطوب	داده‌های بدست آمده از مدل شبکه عصبی
13/7	12/02	6/47	3/93	شرایط خشک	
-	-	1/79	0/6	شرایط مرطوب <sup>1</sup>	
-	-	2/16	0/44	شرایط خشک <sup>2</sup>	داده‌های بدست آمده از مدل اشرفی زاده <sup>1</sup>
1/09	1/09	1/09	1/09	معادله سرعت <sup>3</sup>	

<sup>1</sup> این مدل به صورت  $D=0/443d^{1/5675}$  می‌باشد که D مقاومت به کشش برحسب نیوتن و d عمق خاک‌ورزی برحسب میلی متر است (این معادله برای عمق‌های 30 cm و 40 cm کاربرد ندارد).

<sup>2</sup> این مدل ارائه شده به صورت  $D=0/0121d^{2/2826}$  می‌باشد که D مقاومت به کشش برحسب نیوتن و d عمق خاک‌ورزی برحسب میلی متر است (این معادله برای عمق‌های 30 cm و 40 cm کاربرد ندارد).

<sup>3</sup> مدل مورد نظر به شکل  $D=95/098 S + 800/89$  می‌باشد که D مقاومت به کشش برحسب نیوتن و S سرعت پیشروی بر حسب کیلومتر بر ساعت می‌باشد.

جدول 3- مقایسه داده‌های بدست آمده برای مقاومت به کشش تیغه باریک خاک‌ورز عمودی توسط شبکه مدل عصبی مصنوعی با داده‌های مدل‌های رگرسیونی برای خاک لومی رسی

مقادیر مقاومت به کشش برای یک تیغه باریک خاک‌ورز در عمق مشخص (kN)					منابع داده
40cm	30cm	20cm	10cm		
0/17	0/13	0/08	0/04	خاک با بافت سنگین	استاندارد ASAE
10/51	8/73	5/18	1/55	شرایط مرطوب	داده‌های بدست آمده از آزمایش‌های مزرعه‌ای
11/49	10/92	6/87	3/02	شرایط خشک	
10/88	8/67	5/34	1/79	شرایط مرطوب	داده‌های بدست آمده از مدل شبکه عصبی
11/59	10/94	6/54	3/46	شرایط خشک	
-	-	1/79	0/6	شرایط مرطوب	
-	-	2/16	0/44	شرایط خشک	داده‌های بدست آمده از مدل اشرفی زاده
1/09	1/09	1/09	1/09	معادله سرعت	

## جدول 4 - مقادیر شاخص مخروطی برای خاک‌های مورد استفاده در تحقیق

مقادیر شاخص مخروطی برای یک تیغه باریک خاک‌ورز در عمق مشخص (MPa)				منابع داده	
40cm	30cm	20cm	10cm		
۶/۷۳	۵/۷۹	۳/۸۵	۲/۴۳	شرایط مرطوب	داده‌های بدست آمده از آزمایش‌های مزرعه ای خاک رسی
۸/۴۱	۷/۵۸	۴/۱۷	۲/۳۶	شرایط خشک	لومی
۶/۲۵	۴/۶۳	۳/۱۳	۱/۲۱	شرایط مرطوب	داده‌های بدست آمده از آزمایش‌های مزرعه ای خاک لومی
۷/۹۲	۶/۸۷	۳/۹۳	۱/۱۴	شرایط خشک	رسی
-	۳/۶۲۸	۱/۱۵۳	۰/۷۱۲	شرایط مرطوب	داده های بدست آمده از مدل اشرفی زاده
-	۳/۱۷۲	۱/۰۱۶	۰/۷۰۷	شرایط خشک	

به منظور اندازه‌گیری سرعت واقعی پیشروی تراکتور از چرخ پنجم (شکل 4) استفاده شد (عباسپور گیلانده و همکاران، 2013).



شکل 3- دینامومتر اتصال سه‌نقطه قابل تنظیم مورد استفاده در تحقیق.




شکل 4- چرخ پنجم مورد استفاده در تحقیق به منظور اندازه‌گیری سرعت واقعی تراکتور

برای اندازه‌گیری مقاومت به کشش از یک دینامومتر اتصال سه‌نقطه که توسط عباسپور گیلانده و همکاران (1389 الف) در گروه مهندسی مکانیک ماشین‌های کشاورزی دانشگاه محقق اردبیلی ساخته شده و ارزیابی گردیده بود، استفاده شد (شکل 3). دینامومتر مورد نظر با قابی به شکل U وارونه می‌باشد که بین بازوهای سامانه اتصال سه‌نقطه تراکتور و ادوات کشاورزی سوار می‌شود. دینامومتر اتصال سه‌نقطه به گونه‌ای طراحی گردیده است که دارای قابلیت تنظیم ارتفاع فیل گوش و تنظیم فاصله بین نقاط اتصال پایینی می‌باشد و به راحتی بین تراکتورهای گروه‌های (I) و (II) و ادوات کشاورزی سوار می‌گردد، تا بتوان آن را برای اندازه‌گیری نیروهای افقی و قائم موجود در نقاط اتصال، سامانه اتصال سه‌نقطه تراکتورها و ادوات کشاورزی گروه‌های (I) و (II) به کار برد. واحد حس کننده نیرو شامل سه عدد ترنس‌دیوسر حلقوی نیرو با ساختار هشت وجهی می‌باشد که به‌عنوان عنصر ارتجاعی بین قاب U شکل وارونه و سامانه کوپل اتصال سریع دینامومتر قرار گرفته‌اند.



(الف)



(ب)

شکل 2- (الف) تراکتور مجهز به ابزار اندازه‌گیری دقیق متصل به تیغه خاک‌ورز (ب) تیغه‌های باریک خاک‌ورز عمودی مورد استفاده

## 2-2- آزمایش‌های مزرعه‌ای

آزمایش‌های مزرعه‌ای در مزارع آموزشی و تحقیقاتی دانشکده کشاورزی دانشگاه محقق اردبیلی با دو نوع خاک لومی رسی و رسی لومی انجام شد و در داخل هر نوع خاک از آزمایش فاکتوریل بر پایه طرح بلوک کامل تصادفی (RCBD) و با سه تکرار استفاده شد. مقاومت به کشش در 128 سطح مختلف به تراکتور اعمال شد. ایجاد سطوح کششی توسط 4 تیغه تخت با عرض‌های 2/5، 3/5، 3 و 4 سانتی‌متر و در دو محتوای رطوبتی شرایط خشک و شرایط مرطوب انجام شد. با قرار دادن هر کدام از تیغه‌ها در چهار عمق مختلف و در 4

## 2-4- داده‌های مورد استفاده در شبکه عصبی مصنوعی طراحی شده

مهمترین عامل در طراحی شبکه‌های عصبی مصنوعی انتخاب داده‌های مورد استفاده در آموزش و یادگیری شبکه می‌باشد. عناصر بردارهای ورودی باید به گونه‌ای انتخاب شوند که بتوانند شرایط حاکم بر سامانه را به خوبی نشان دهند. از آنجایی که هدف از توسعه مدل شبکه عصبی مصنوعی در این تحقیق پیش‌بینی نیروی مقاوم کششی تیغه باریک خاک‌ورز می‌باشد، بنابراین بردارهای ورودی از میان پارامترهای مؤثر بر آنها انتخاب می‌گردند.

در این تحقیق پارامترهای ورودی به شبکه عصبی مصنوعی درصد محتوی رطوبتی خاک، سرعت پیشروی تراکتور، مقادیر شاخص مخروطی خاک، عمق نفوذ تیغه و عرض برش تیغه می‌باشند. مقاومت به کشش ابزار باریک خاک‌ورز پارامتر خروجی شبکه طراحی شده می‌باشد.

داده‌های مورد استفاده در این تحقیق که به منظور پیش‌بینی مقاومت به کشش ابزار باریک خاک‌ورز عمودی مورد استفاده قرار گرفتند از داده‌های آزمایشات مزرعه‌ای انجام شده بدست آمدند. انتخاب داده‌ها به نحوی بود که بتوانند تغییرات هر یک از پارامترهای مؤثر را در امر پیش‌بینی به خوبی بیان کرده و شرایط واقعی حاکم بر مزارع آزمایشی را به خوبی نشان دهند.

برای آموزش شبکه طراحی شده و نیز آزمون شبکه باید داده‌های جمع‌آوری شده به سه فایل جداگانه تقسیم می‌شدند. بنابراین تمام داده‌های جمع‌آوری شده که به صورت فایل txt بودند، به صورت یک کاربردگر در صفحه گسترده اکسل تبدیل شدند. در این کاربردگر پارامترهای اندازه‌گیری شده در یک ردیف و داده‌های این پارامترها در ستون‌هایی قرار گرفتند که این داده‌ها شامل ورودی‌ها و خروجی مدنظر می‌شدند.

از کل داده‌های مورد نظر 50 درصد به منظور آموزش شبکه و 25 درصد برای آزمون شبکه و 25 درصد دیگر به منظور اعتبار بخشی<sup>5</sup> شبکه مورد استفاده قرار گرفتند.

## 3- نتایج و بحث

بطوریکه اشاره شد در این تحقیق از شبکه‌های پس انتشار چندلایه به منظور پیش‌بینی مقاومت به کشش یک تیغه باریک خاک‌ورز عمودی استفاده می‌شود. به منظور آموزش شبکه از سه نوع الگوریتم گرادیان نزولی با مومنتم (GDM)، الگوریتم گرادیان مزدوج مقیاسی (SCG) و الگوریتم لونیبرگ-مارکوات (LM) استفاده گردید. بررسی‌های اولیه نشان داد که شبکه‌های ساخته شده با استفاده از الگوریتم‌های LM و SCG بعد از طی 300 سیکل در مقدار خطای

سرعت پیشروی مختلف 128 سطح کششی ایجاد شد و آزمایشات در سطوح کششی مختلف انجام گرفت. مقادیر مقاومت به کشش ابزار باریک خاک‌ورزی با 3 تکرار در هر سطح اندازه‌گیری و در سامانه تحصیل داده ذخیره شده و پس از انتقال به کامپیوتر مورد تجزیه و تحلیل قرار گرفت.

## 2-3- طراحی مدل با استفاده از شبکه عصبی مصنوعی

شبکه‌های طراحی شده در این تحقیق که به منظور پیش‌بینی نیروی مقاوم کششی ابزار باریک خاک‌ورزی مورد استفاده گرفتند، از نوع شبکه‌های چندلایه پس انتشار خطا می‌باشند. از سه روش الگوریتم گرادیان نزولی با مومنتوم، الگوریتم لونیبرگ-مارکوات و الگوریتم گرادیان نزولی مقیاسی به منظور آموزش شبکه استفاده گردید. شبکه‌های چندلایه در کارهای پیش‌بینی قابلیت بسیار خوبی را از خود نشان می‌دهند؛ به شرطی که نرون کافی در لایه مخفی وجود داشته باشد. اما باید به این نکته توجه داشت که تعداد نرون‌های بیشتر در لایه مخفی ممکن است شبکه را دچار آموزش بیش از حد کرده و ممکن است شبکه قابلیت تعمیم خود را از دست بدهد. در حالت کلی نمی‌توان در مورد تعداد لایه‌های مخفی و نیز تعداد مناسب نرون‌های لایه مخفی اظهار نظر قطعی کرد و انتخاب تعداد نرون‌های لایه میانی به صورت سعی و خطا انجام می‌گیرد. در این تحقیق نیز تعداد لایه‌های مخفی و تعداد نرون‌ها در لایه میانی متناسب با تعداد نرون‌های لایه میانی بر مبنای مقایسه عملکرد شبکه‌ها انتخاب شد. همچنین در این تحقیق از توابع تبدیل تانژانت سیگموئیدی، هیپربولیک و تابع محرک خطی بین لایه‌های شبکه استفاده شد.

بهترین روش آموزش برای داده‌های مورد استفاده و همچنین مقایسه عملکرد شبکه‌های ساخته شده بر اساس معیارهای میانگین مربعات خطا<sup>1</sup> (MSE)، مجموع مربعات خطا<sup>2</sup> (SSE) و ضریب تبیین<sup>3</sup> ( $R^2$ ) مدل برازش شده خطی بین داده‌های واقعی و داده‌های پیش‌بینی شده انجام می‌گردد. به منظور مقایسه آماری میزان دقت شبکه‌های طراحی شده، از معیار دقت پیش‌بینی مدل استفاده می‌گردد. میزان دقت پیش‌بینی مدل<sup>4</sup> (P.A.) نسبت اختلاف بین داده‌های واقعی با داده‌های پیش‌بینی شده به داده‌های واقعی تعریف می‌گردد (علیمردانی و همکاران 2009).

<sup>1</sup>-Mean Square Error

<sup>2</sup>-Sum Square Error


<sup>3</sup>-Coefficient of Determination

<sup>4</sup>-Prediction Accuracy

<sup>5</sup>-Validation

پس از هر بار آموزش شبکه (در هر الگوریتم و برای هر تعداد نرون پنهان) نموداری که نشانگر روند تغییرات خطای داده‌های آموزشی، ارزیابی و تست شبکه است در نرم‌افزار MATLAB ترسیم می‌گردد (شکل 7).

نمودارهای رگرسیون در مراحل آموزش، ارزیابی، تست و کل به‌طور مجزا نشان داد که بالاترین ضریب همبستگی 0/99424 به مرحله آموزش اختصاص دارد. همچنین ضریب همبستگی مراحل ارزیابی و تست به ترتیب 0/97458 و 0/96022 می‌باشند. میانگین دقت شبیه‌سازی در مراحل آموزش، ارزیابی و آزمون به ترتیب 94/68 و 96/92 و 95/05 درصد می‌باشند. جدول 1 شاخص‌های کمی ارزیابی شبکه‌های ساخته شده با استفاده از الگوریتم آموزشی لونیبرگ-مارکوات را نشان می‌دهد. همانطور که از جدول پیداست شبکه ساخته شده با 8 نرون در لایه مخفی دارای بالاترین دقت شبیه‌سازی و بالاترین ضریب همبستگی می‌باشد.

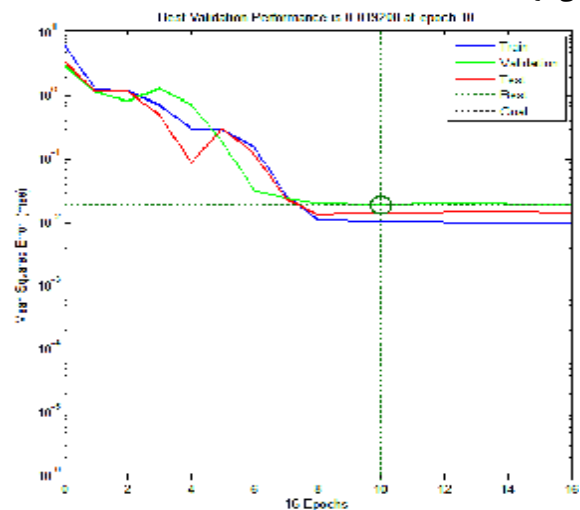


شکل 6- نمودار رگرسیون شبکه با 8 نرون در لایه پنهان

به منظور ارزیابی مدل شبکه عصبی مصنوعی توسعه داده شده، داده‌های بدست آمده از این مدل با داده‌های مدل‌های رگرسیونی موجود برای پیش‌بینی نیروی مقاوم کششی یک تیغه باریک خاک‌ورز عمودی مورد مقایسه قرار گرفتند. مدل‌های رگرسیونی مورد استفاده در این تحقیق شامل مدل ارائه شده توسط انجمن مهندسی کشاورزی آمریکا (بی‌نام، 2001 الف، و بی‌نام، 2001 ب)، مدل گارنر<sup>1</sup> و همکاران (1987) و نیز مدل ارائه شده توسط اشرفی زاده (2006) می‌باشد. نتایج استفاده از مدل گارنر و همکاران (1987) نشان داد که این مدل برای عمق‌های 0 تا 10 سانتی‌متر کارایی لازم را ندارد. بنابراین

MSE شبکه‌ها کاهش چندانی مشاهده نمی‌شود، اما به منظور حصول اطمینان بیشتر از رسیدن به حداقل خطا و حداکثر پایداری، تا 1000 تکرار ادامه داده شدند. تعداد تکرارهای شبکه برای رسیدن به حداقل خطا با استفاده از الگوریتم GDM تا 10000 تکرار هم مشاهده شد. از معیار بیشترین ضریب همبستگی، بالاترین دقت شبیه‌سازی در داده‌های آزمایشی، کمترین MSE و تعداد تکرار شبکه برای تعیین بهترین الگوریتم آموزشی استفاده شد. در بین الگوریتم‌های مذکور الگوریتم LM مناسب‌ترین الگوریتم با بالاترین ضریب همبستگی و بالاترین دقت شبیه‌سازی شناخته شد. همچنین این الگوریتم از میانگین مربعات خطای مناسبی برخوردار است. همچنین مشاهده شد که تابع انتقال logsig در الگوریتم لونیبرگ-مارکوات از عملکرد بهتری در مقایسه با tansig برخوردار است.

در شکل 5 جهت کنترل بهتر و دقیق‌تر فرآیند آموزش شبکه و بررسی پدیده بیش‌برازش نمودار MSE بر حسب Epoch ترسیم شده است. به تعداد تکرارها مجموع مربعات خطا وجود دارد که از نمایش تغییرات آن به عنوان معیاری جهت فهم عملکرد شبکه استفاده می‌شود.



شکل 5- نمودار عملکرد شبکه لونیبرگ-مارکوات با 8 نرون در لایه پنهان

در شکل 6 نموداری که نشانگر بهترین خط برازش یافته بین مقادیر نیروی مقاوم کششی واقعی (T) و پیش‌بینی شده توسط شبکه (Y) نشان داده شده است و ضریب همبستگی رگرسیون بین آنها 0/9935 استخراج شده است. شبکه ساخته شده با 8 نرون دارای بیشترین شیب، کمترین عرض از مبدا و بیشترین ضریب همبستگی است. این مقادیر به ترتیب 0/9729، 0/1833 و 0/9935 می‌باشند. به دلیل حجم انبوه نمودارها فقط نمودارهای مربوط به بهترین الگوریتم (trainlm) و مناسب‌ترین تعداد نرون (8 عدد) در لایه مخفی ارائه شده است.

<sup>1</sup>-Garner

به خاک می‌باشد که برای خاک با بافت سنگین برابر 1، برای خاک با بافت متوسط 0/70 و برای خاک با بافت شنی 0/45 در نظر گرفته می‌شود.

جدول 3 مقایسه داده‌های بدست آمده برای مقاومت به کشش تیغه باریک خاک‌ورزی توسط شبکه عصبی با داده‌های مدل‌های رگرسیونی برای خاک لومی‌رسی را نشان می‌دهد. در این نوع خاک نیز داده‌های پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی اختلاف اندکی با داده‌های واقعی دارند. اما این داده‌ها در مقایسه با داده‌های بدست آمده از مدل ارائه شده توسط انجمن مهندسين کشاورزی آمریکا (ASAE) و مدل ارائه شده توسط اشرفی زاده و همکاران (2006) بزرگتر می‌باشند. علت این اختلاف ناشی از فشرده‌گی خاک‌های مورد استفاده در این تحقیق می‌باشد.

جدول 4 مقایسه مقادیر شاخص مخروطی برای خاک‌های مورد استفاده در این تحقیق و شاخص مخروطی بدست آمده از مدل اشرفی زاده و همکاران (2006) را نشان می‌دهد. همان‌طوریکه از جدول پیداست در مزارع آزمایشی در این تحقیق با افزایش عمق خاک‌ورزی شاخص مخروطی افزایش می‌یابد و دلیل اختلاف بین داده‌های مدل شبکه عصبی مصنوعی و مدل‌های رگرسیونی در بالا بودن مقاومت مکانیکی خاک در مزارع آزمایشی می‌باشد. هیچکدام از مدل‌های رگرسیونی بکارگرفته شده در این مقایسه اثر مقاومت مکانیکی خاک را در پیش‌بینی نیروی مقاوم کششی در نظر نگرفته‌اند.

#### 4- نتیجه‌گیری نهایی

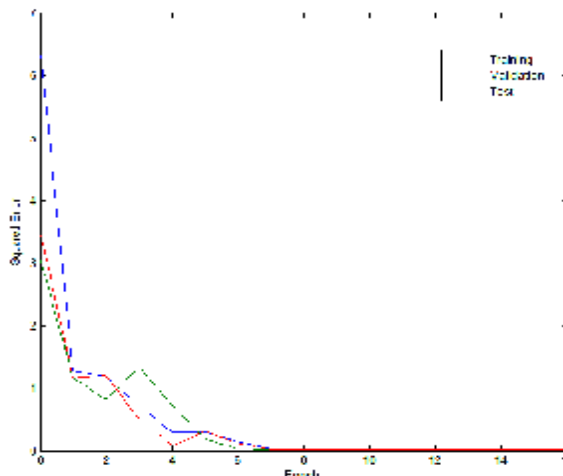
1- در این تحقیق از شبکه‌های پس انتشار چندلایه به‌منظور پیش‌بینی مقاومت به کشش یک تیغه باریک خاک‌ورز عمودی استفاده شد. به منظور آموزش شبکه از سه نوع الگوریتم گرادیان نزولی با مومنتم، الگوریتم گرادیان مزدوج مقیاسی و الگوریتم لونیبرگ-مارکوات استفاده گردید.

2- نتایج نشان داد که الگوریتم لونیبرگ-مارکوات با یک لایه مخفی با تعداد 8 نرون در لایه در مقایسه با دیگر الگوریتم‌ها دارای دقت شبیه‌سازی بالای 95/05% و نیز ضریب همبستگی بالای 0/9935 می‌باشد.

3- داده‌های بدست آمده از مدل شبکه عصبی مصنوعی با مدل‌های ASAE و مدل اشرفی‌زاده مقایسه شدند. نتیجه این مقایسه نشان داد که داده‌های پیش‌بینی شده توسط شبکه عصبی مصنوعی خیلی نزدیک به داده‌های واقعی بدست آمده از آزمایشات مزرعه‌ای می‌باشند.

4- هیچکدام از مدل‌های رگرسیونی بکارگرفته شده در این مقایسه اثر مقاومت مکانیکی خاک را در پیش‌بینی مقاومت به کشش در نظر نگرفته‌اند و نتوانستند کاربرد چندانی برای پیش‌بینی مقاومت به کشش در خاک‌های مورد مطالعه داشته باشند.

نمی‌توان داده‌های واقعی را با این مدل در عمق‌های مذکور مقایسه کرد.



شکل 7- روند تغییرات خطای داده‌های آموزش، ارزیابی و تست

جدول 2 مقایسه داده‌های بدست آمده برای نیروی مقاوم کششی تیغه باریک خاک‌ورزی توسط شبکه عصبی با داده‌های مدل‌های رگرسیونی برای خاک لومی‌رسی را نشان می‌دهد. همان‌طور که از این جدول مشخص است داده‌های پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی بسیار نزدیکتر به داده‌های واقعی بدست آمده از آزمایشات مزرعه‌ای می‌باشد. اما داده‌های پیش‌بینی شده توسط مدل شبکه عصبی در مقایسه با داده‌های بدست آمده از مدل ارائه شده توسط انجمن مهندسين کشاورزی آمریکا (ASAE) بزرگتر می‌باشند. همچنین مقایسه بین داده‌های پیش‌بینی شده و مدل ارائه شده توسط اشرفی‌زاده و همکاران (2006) نشان داد که بین داده‌های پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی و داده‌های بدست آمده از مدل اشرفی‌زاده اختلاف وجود دارد. البته توجه به این نکته ضروری است که مدل ارائه شده توسط اشرفی‌زاده شامل سه فرمول مجزا می‌باشد که عامل‌های مؤثر بر مقاومت به کشش به صورت جداگانه در نظر گرفته شده‌اند.

انجمن مهندسين کشاورزی آمریکا (ASAE) نیروی کششی مورد نیاز ادوات خاک‌ورزی را برای سه حالت خاک؛ خاک با بافت سنگین، خاک با بافت متوسط و خاک با بافت سبک ارائه کرده است. مدل ارائه شده توسط ASAE به صورت  $D = F_i [A + B(S) + C(S^2)] WT$  می‌باشد که در آن  $D$  نیروی کششی بر حسب نیوتن،  $S$  سرعت پیشروی بر حسب کیلومتر بر ساعت و  $W$  عرض وسیله خاک‌ورزی بر حسب متر و  $T$  عمق کار وسیله خاک‌ورزی بر حسب سانتی‌متر می‌باشد.  $F_i$  شاخص (ضریب) مربوط



## منابع مورد استفاده

عباسپور گیلانده، ی.، س. حقیقت شیشوان، و. رسولی شربینانی، و ض. فاضل نیاری - 1389 الف. طراحی، ساخت و واسنجی دینامومتر اتصال سه نقطه قابل تنظیم برای تراکتورهای کشاورزی رایج در ایران. فصلنامه تحقیقات مهندسی کشاورزی، سال یازدهم، شماره 2، صفحات 29-48.

عباسپور گیلانده، ی.، م. آهنی، ع. عسکری اصلی ارده، و. رسولی شربینانی - 1389 ب. طراحی، ساخت و ارزیابی نفوذسنج مخروطی پشت تراکتوری مجهز به میله‌های نفوذ چندانگانه. فصلنامه تحقیقات مهندسی کشاورزی، سال یازدهم، شماره 1، صفحات 19-34.

Abbaspour-Gilandeh, Y., F. Rashidi-Mohammadabad. 2013. *Evaluation of dynamic load equations through continuous measurement of some tractor tractive performance parameters*. International Journal of Heavy Vehicle Systems. 20 (3): 222-235.

Alimardani, R., Y. Abbaspour-Gilandeh, A. Khalilian, A. Keyhani, and S. H. Sadati. 2009. *Prediction of draft force and energy of subsoiling operation using ANN model*. International Journal of Food, Agriculture and Environment (JFAE). 7(3, 4): 537-542.

Al-Janobi, A. A., A. M. Aboukarima, and K. A. Ahmed. 2001. *Prediction of specific draft of different tillage implements using neural network*. MISR Journal of Agricultural Engineering. 18(3): 699-714.

Anon. 2003a. ASAE Standards. D497.4: *Agricultural machinery management data*. ASAE. St. Joseph, MI 49085-9659, USA.

Anon. 2003b. ASAE Standards. EP496.2: *Agricultural machinery management data*. ASAE. St. Joseph, MI 49085-9659, USA.

Ashrafizadeh, S. R. 2006. *Modeling of energy requirements by a narrow tillage Tool*. Doctor of Philosophy Thesis. Agricultural and Bioresource Engineering Department. University of Saskatchewan. Canada.

Choi, Y. S., K. S. Lee, and W. Y. Park. 2000. *Application of a neural network to dynamic draft model*. Agricultural and Biosystems Engineering. 1(2): 67-72.

Garner, T. H., W. R. Reynolds, H. L. Musen, G. E. Miles, J. W. Davis, W. Dam, and U. M. Peiper. 1987. *Energy requirement for subsoiling coastal plain soils*. Transactions of the ASAE. 30(2):343-349.

Kushwaha, R. L., and Z. X. Zhang. 1998. *Evaluation of factors and current approaches related to computerized design of tillage tools: a review*. Journal of Terramechanics. 35(2):69-86.

Manuwa, S. I. and O. C. Ademosun. 2007. *Draught and soil disturbance of model tillage tines under varying soil parameters*. Agricultural Engineering International: the CIGR Ejournal. Manuscript PM 06 016. Vol. IX. March, 2007.

Roul, A. K., H. Raheman, M. S. Pansare, and R. Machavaram. 2009. *Predicting the draught requirement of tillage implements in sandy clay loam soil using an artificial neural network*. Biosystems Engineering. 104 (2009): 476 - 485.

Zhang, Z. X., and R. L. Kushwaha. 1999. *Application of neural networks to simulate soil tool interaction and soil behavior*. Canadian Agricultural Engineering. 41(2): 119-125.



## Draft Prediction of a Vertical Narrow Tillage Tool by Artificial Neural Networks

Yousef Abbaspour-Gilandeh<sup>1\*</sup>, Hamid Jalilnejhad<sup>2</sup> and Tarahom Mesri Gundoshmian<sup>3</sup>

<sup>1</sup>Dept. of Agricultural Machinery, Faculty of Agricultural Technology and Natural Resources, University of Mohaghegh Ardabili, Iran

<sup>2</sup>Dept. of Agricultural Machinery, Faculty of Agricultural Technology and Natural Resources, University of Mohaghegh Ardabili, Iran

<sup>3</sup>Dept. of Agricultural Machinery, Faculty of Agricultural Technology and Natural Resources, University of Mohaghegh Ardabili, Iran

\*Corresponding Author E-mail: [abbaspour@uma.ac.ir](mailto:abbaspour@uma.ac.ir)

### Abstract

Draft of different tillage tools is an important parameter for performance measurement, evaluation of tillage tools and also for determining the amount of required energy. Prediction of this parameter could be beneficial in many farm management practices, prediction of energy requirements and selecting appropriate tractor. In this study, field experiments were carried out at two soil types, namely, clay loam and loam clay, for predicting draft of a vertical narrow tillage tool, using artificial neural network and also, for comparison of developed model accuracy with that of regression models. Some parameters such as soil types, soil conditions, tools parameters and operational parameters were selected as inputs to artificial neural network. Within each type of soil, experiments were conducted in the form of factorial experiment based on randomized complete block design (RCDB) with three replications. Different levels of soil moisture content (factor A) 5-16 percent for dry soil and 17-38 percent for wet soil, tractor speed (factor B) at four levels of 1, 1.5, 1.8 and 3 km/hr, working depth (factor C) at four levels of 10, 20, 30 and 40cm and blade width (factor D) in four levels of 2.5, 3, 3.5 and 4cm were selected. Back propagation neural networks with three different training algorithms (gradient descending algorithm with momentum, descending scaled gradient and Levenberg-Marquardt) were adopted to predict the draft. Back propagation neural networks with Levenberg-Marquardt training algorithm presented better accuracy in simulation (95.05%) and correlation coefficient ( $R^2$ ) of 0.9935 as compared to others. The obtained data from neural network model were compared to ASAE and Ashrafizadeh (2006) models; the result showed that the predicted data by artificial neural network were very close to real data obtained from field experiments and the regression models did not have much proficiency for predicting draft at the studied area.

**Keywords:** Artificial neural network, Draft, Levenberg-Marquardt training algorithm, Vertical narrow tillage tool