



## تبیین پارامترهای پایداری محیطی با استفاده از شبکه عصبی مصنوعی

مرتضی رهبر<sup>1</sup>، محمدجواد مهدوی نژاد<sup>2</sup>، محمدرضا بمانیان<sup>3</sup> و امیرحسین دوائی مرکزی<sup>4</sup>

تاریخ دریافت: 97/09/18

تاریخ پذیرش: 97/10/29

**چکیده:** پژوهش حاضر، با تأکید بر قابلیت هوش مصنوعی در پیش‌بینی پارامترهای پایداری محیطی، به مطالعه فرآیند استفاده از الگوریتم شبکه عصبی مصنوعی در پیش‌بینی میزان انرژی تابشی دریافتی در یک بافت شهری می‌پردازد. در این راستا ابتدا مجموعه داده‌های آموزشی از طریق فرآیندهای قاعده محور تهیه می‌شود و سپس با استفاده از فرآیند داده‌محور، سه شبکه عصبی مصنوعی آموزش داده شده و سه تابع برازش جداگانه برای آن تقریب زده می‌شود. این توابع بر اساس سه ساختار متفاوت از شبکه‌های عصبی مصنوعی تنظیم شده‌اند. در پایان با مقایسه میزان خطای هر مدل، مقادیر پیش‌بینی شده نیز مورد بررسی قرار می‌گیرد و تأثیر ساختار شبکه عصبی در پاسخ‌های به دست آمده، تحلیل می‌شود. مدل ارائه شده این پژوهش قابلیت تعمیم پذیری به سایر مسأله‌های مشابه پیش‌بینی پارامترهای پایداری محیطی را دارد و دو کاربرد اساسی برای این مدل‌ها وجود دارد. ابتدا امکان محاسبه دقیق و بدون نیاز به محاسبات سنگین را ایجاد می‌کند و دوم در شبیه‌سازی‌های پیچیده با در اختیار داشتن پارامترهای مستقل و وابسته و بدون نیاز به مطالعه قواعد و قوانین حاکم، قابلیت تخمین تابع را دارد و می‌تواند پارامتر پایداری مد نظر را با دقت بالا پیش‌بینی کند.

**واژگان کلیدی:** هوش مصنوعی، شبکه عصبی مصنوعی، انرژی تابشی دریافتی، فرآیند داده‌محور.

<sup>1</sup> استادیار، معماری، دانشکده معماری و شهرسازی، دانشگاه علم و صنعت ایران، تهران، ایران.

<sup>2</sup> دانشیار، معماری، دانشکده هنر و معماری، دانشگاه تربیت مدرس، تهران، ایران. (نویسنده مسئول)، پست الکترونیکی: mahdavinejad@modares.ac.ir

<sup>3</sup> استاد، معماری، دانشکده هنر و معماری، دانشگاه تربیت مدرس، تهران، ایران.

<sup>4</sup> استاد، مکانیک، دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران.

## 1- مقدمه

عصر دیجیتال قابلیت‌ها و تکنیک‌های جدیدی را در حوزه طراحی معماری ایجاد کرده است. امروزه طراحی، تحلیل و ساخت پروژه‌های معماری توسط نرم‌افزارهای متنوعی انجام می‌شود و به وضوح می‌توان دید که اهمیت استفاده از هوش مصنوعی در کنار هوش انسانی بیش از پیش برای معماران روشن شده است. در معماری، هر گونه مسأله‌ای که قابلیت کدگذاری ریاضیاتی را داشته باشد، می‌تواند به عنوان یک مسأله حوزه هوش مصنوعی تعریف شود و با استفاده از الگوریتم‌های موجود به حل آنها پرداخت. به طور اخص، حوزه تحلیل پارامترهای انرژی و پایداری محیطی دارای ضوابط و قواعد مشخصی است که فرمول‌های نرم‌افزاری ویژه‌ای برای آنها تعریف شده است. این معادلات سعی دارند اتفاقات دنیای واقعی پیرامون را با دقت بالایی در فضای نرم‌افزاری شبیه‌سازی کنند (Javanroodi et al., 2018, MahdaviNejad and Javanroodi, 2016). با این حال در بسیاری از مطالعات موردی، پاسخ‌های حاصل از شبیه‌سازی با واقعیت محیطی تفاوت دارند که گویای پیچیدگی شبیه‌سازی پارامترهای محیطی تأثیرگذار است (Talaie et al., 2017). در این موارد پژوهشگر باید با صرف وقت و دقت زیاد تمام پارامترهای محیطی را مجدداً مطالعه و همه آنها را در محیط نرم‌افزاری شبیه‌سازی و روابط بین آنها را با دقت بالا تعریف کند. پس از طی این مراحل، تمام شبیه‌سازی‌های انجام شده توسط موتور محاسباتی نرم‌افزارها و با صرف زمان‌های طولانی محاسبه می‌شوند (MahdaviNejad and Nazar, 2017). لذا دو موضوع پیچیدگی تعریف پارامترهای دخیل در مسأله‌های شبیه‌سازی پایداری محیطی و زمان محاسبات طولانی آنها از مشکلات موجود در اکثر مطالعات این حوزه به حساب می‌آید. مقاله حاضر با استفاده از روش‌های داده‌محور<sup>1</sup> الگوریتم‌های هوش مصنوعی، راهکاری را جهت شبیه‌سازی یک تابع محاسباتی در مسأله‌های پایداری محیطی ارائه می‌کند که می‌تواند الگویی برای پژوهشگران این حوزه در شبیه‌سازی‌های مرتبط به حساب آید.

در پژوهش حاضر، میزان تابش دریافتی در یک بافت شهری به عنوان مطالعه موردی بررسی شده است و با استفاده از آموزش یک شبکه عصبی مصنوعی، تابعی برای شبیه‌سازی میزان تابش دریافتی تخمین زده می‌شود. هدف از آموزش و تخمین تابع، دستیابی به دقت لازم در محاسبه میزان انرژی تابشی دریافتی توسط شبکه عصبی مصنوعی است. برای آموزش شبکه عصبی مصنوعی باید یک مجموعه داده آموزشی<sup>2</sup> مرتبط تهیه شود. این مجموعه داده، شامل پارامترهای متغیر و پاسخ تابع هدف است. برای تهیه داده‌های مورد نظر می‌توان به دو روش اقدام کرد. روش اول، برداشت محیطی میزان تابش دریافتی در بافت شهری است و روش دوم شبیه‌سازی میزان تابش دریافتی در نرم‌افزار محاسبات انرژی است. پس از تهیه داده‌های مورد نظر، شبکه عصبی مصنوعی می‌تواند با دریافت پارامترهای متغیر و پاسخ تابش دریافتی هر حالت، یک تابع و فرمول غیر خطی برای آن محاسبه کند و برای نقاط جدید موجود در سایت، بدون نیاز به برداشت محیطی یا شبیه‌سازی نرم‌افزاری در زمانی کمتر از یک ثانیه و با دقت بالا پاسخ را ارائه دهد. در پژوهش حاضر از روش شبیه‌سازی نرم‌افزاری برای تهیه مجموعه داده‌های آموزشی شبکه عصبی مصنوعی استفاده شده است. تمام فرآیندهای ارائه شده می‌تواند به روش برداشت محیطی تعمیم داده شود و در موضوعات مشابه، الگوریتم ارائه شده می‌تواند به عنوان الگور مورد استفاده قرار گیرد.

استفاده از الگوریتم شبکه عصبی مصنوعی در شبیه‌سازی پارامترهای پایداری، به عنوان یکی از پرکاربردترین الگوریتم‌های هوش مصنوعی، از دو جهت حائز اهمیت است. اهمیت اول، قابلیت محاسبه و پیش بینی پارامترهای محیطی بر اساس مشاهدات پیشین است که التزام به تعریف روابط بین پارامترها را برطرف می‌کند. این موضوع در بسیاری از مسأله‌ها که تعریف پارامتریک آنها پیچیده است، دوچندان اهمیت پیدا می‌کند. نکته دوم در قابلیت محاسبه سریع و با دقت بالا بر اساس مشاهدات شبیه‌سازی نرم‌افزاری است. این موضوع در مسأله‌هایی که امکان شبیه‌سازی پارامتریک وجود دارد ولی زمان محاسبات بسیار طولانی دارد اهمیت پیدا

سنجی مورد نظر، ایجاد نشده باشد دوباره در ساختار شبکه عصبی بازنگری می‌شود و سعی می‌شود با تغییراتی ظرفیت<sup>9</sup> دقت مطلوب ایجاد گردد. پس از کسب دقت اعتبارسنجی، حال باید دقت مدل هوش مصنوعی با داده‌های آزمایش سنجیده شود. در این مرحله مشخص می‌شود که تا چه میزان مدل آموزش دیده قابلیت تعمیم‌پذیری دارد. در صورتی که دقت مطلوب نباشد، دوباره در یک فرآیند برگشتی ساختار اصلی شبکه عصبی مصنوعی تغییر می‌کند تا نتیجه این قسمت نیز به مطلوب‌ترین حالت خود نزدیک شود. پس از کسب دقت مطلوب در آزمایش مدل، حال می‌توان از مدل ایجاد شده در پیش‌بینی متغیرهای وابسته بر اساس متغیر جدید مستقل استفاده کرد. مدل شبکه عصبی مصنوعی آموزش دیده در اصل همان تابع غیر خطی است که قابلیت تقریب متغیر وابسته بر اساس متغیر مستقل با دقت بالا را کسب کرده است. در جدول 1 فهرست علائم و اختصارات این مقاله ارائه شده است.

جدول 1 - فهرست علائم و اختصارات

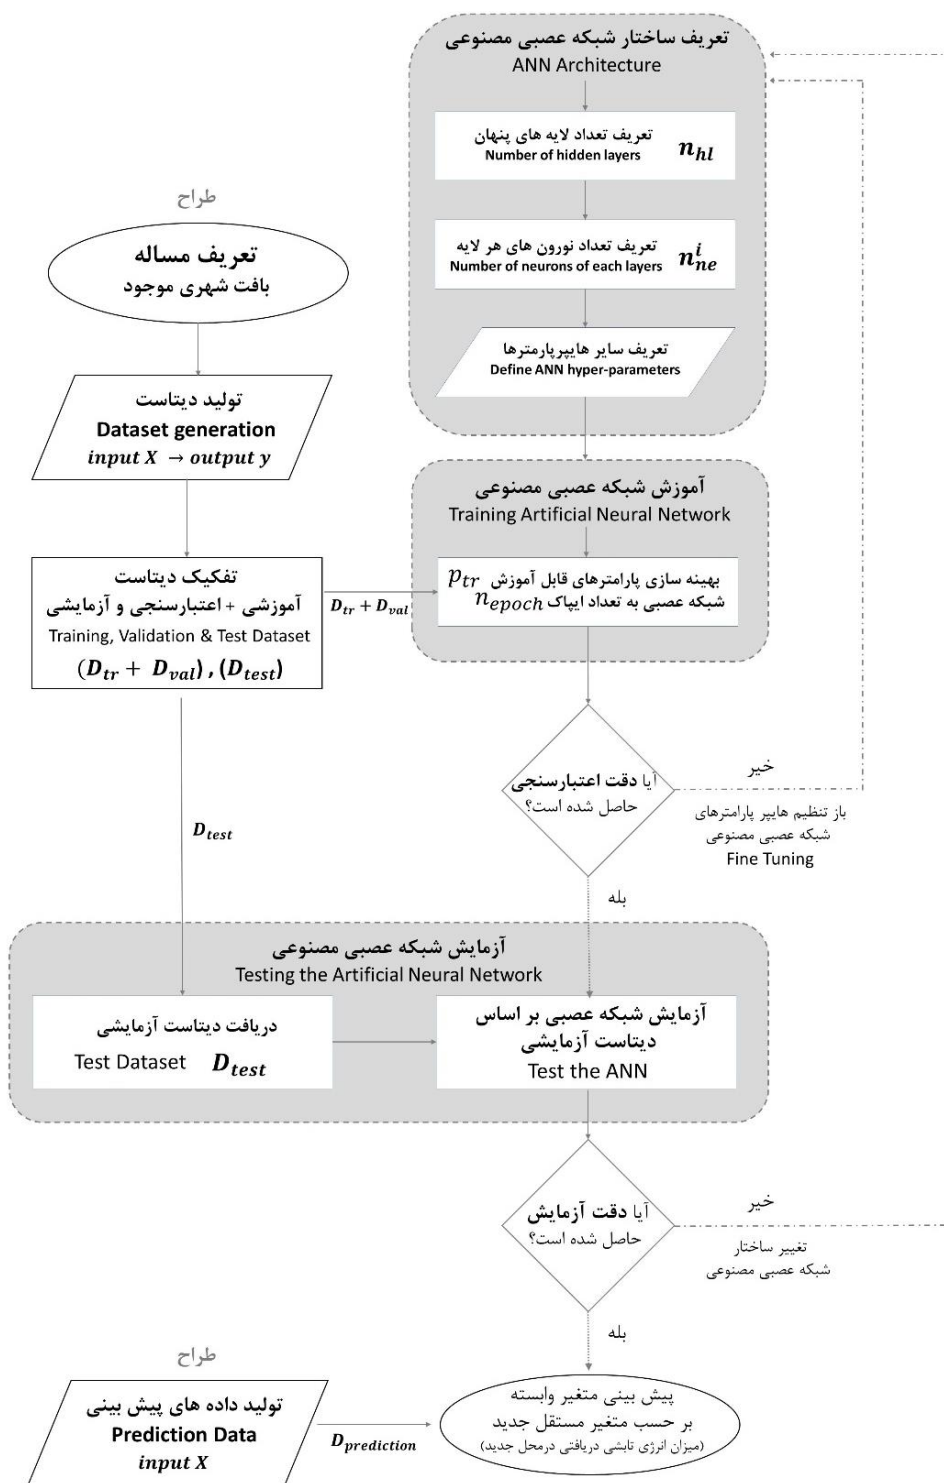
Tab. 1 - Nomenclature

علامت	توضیحات
$input X$	متغیرهای مستقل
$output y$	متغیرهای وابسته
$D_{tr}$	دیتاست آموزشی
$D_{val}$	دیتاست اعتبارسنجی
$D_{test}$	دیتاست آزمایش
$D_{prediction}$	دیتاست و یا داده‌های پیش‌بینی
$n_{hl}$	تعداد لایه‌های پنهان شبکه عصبی مصنوعی
$n_{ne}^i$	تعداد نرون‌های لایه $i$ ام شبکه عصبی مصنوعی
$p_{tr}$	پارامترهای قابل آموزش در شبکه عصبی مصنوعی
$n_{epoch}$	تعداد اپیک‌های آموزش شبکه عصبی مصنوعی
$loss$	تابع هزینه - معیار اندازه‌گیری میزان خطا پیش‌بینی مدل و مقدار واقعی
$loss_{val}$	تابع هزینه داده‌های اعتبارسنجی
$hL_i$	لایه پنهان $i$ ام
$w_{ij}^k$	پارامتر وزنی یال اتصال دهنده نرون $i$ ام لایه $k-1$ به نرون $j$ ام لایه $k$
$A_i^j$	مقدار عددی نرون $i$ ام لایه $j$
$x_i$	پارامتر مستقل $i$ ام
$\hat{y}$	پارامتر وابسته پیش‌بینی شده
$f_{act}$	تابع فعال‌سازی
$\theta_i^j$	ضرب تمایل نرون $i$ ام لایه $j$

می‌کند و تابع محاسبه شده شبکه عصبی مصنوعی می‌تواند با دقت بالا و در زمانی کوتاه محاسبات مورد نظر را انجام دهد.

در پژوهش حاضر، ابتدا مجموعه داده‌های آموزشی شبکه عصبی مصنوعی که میزان تابش دریافتی در بافت شهری است با استفاده از روش شبیه‌سازی نرم‌افزاری تهیه می‌شود. سپس با مطالعه در ساختار شبکه عصبی مصنوعی، الگوهای متفاوت و تعداد لایه‌های پنهان و تعداد نرون‌های مورد نیاز در شبکه عصبی مورد بررسی قرار می‌گیرد. سپس با انجام آزمایش بر روی الگوهای شبکه‌های عصبی مصنوعی، بهترین الگو برای محاسبه و پیش‌بینی انتخاب می‌شود. در پایان، دلایل و ساختار مستخرج از آزمایش‌ها مورد نقد و تحلیل قرار می‌گیرد و مخاطب با مطالعه مقاله حاضر می‌تواند در مطالعات محاسبات پایداری محیطی از الگو شبکه عصبی مصنوعی ارائه شده استفاده کند. در مجموع هدف از این پژوهش ارائه راهکاری جهت محاسبه دقیق پارامترهای پایداری محیطی با استفاده از روش‌های داده محور هوش مصنوعی است.

در شکل شماره 1، فلوچارت الگوریتم این پژوهش ارائه شده است. ورودی اصلی، تعریف مسأله است که توسط طراح بیان می‌شود. خروجی اصلی نیز پیش‌بینی متغیر وابسته بر اساس متغیرهای مستقل جدید است. جزئیات هر قسمت از فلوچارت در متن این پژوهش به تفصیل تشریح شده است. در نگاهی کلان پس از تعریف مسأله، مجموعه داده‌های آموزشی (دیتاست<sup>3</sup>) تهیه می‌شود. دیتاست ایجاد شده به دو دسته آموزشی<sup>4</sup>  $D_{tr}$  + اعتبارسنجی<sup>5</sup>  $D_{val}$  و دسته آزمایشی<sup>6</sup>  $D_{test}$  تقسیم می‌شود. پس از تهیه دیتاست، ساختار شبکه عصبی مصنوعی تعریف می‌شود. مهم‌ترین هاپیرپارامتر تأثیرگذار در تعریف ساختار شبکه عصبی تعداد لایه‌های پنهان<sup>7</sup>  $n_{hl}$  و همچنین تعداد نرون‌های هر لایه<sup>8</sup>  $n_{ne}^i$  است که به دقت تنظیم می‌شوند. سایر هاپیرپارامترها نیز در ساختار شبکه عصبی مصنوعی تعریف می‌شوند. پس از تعریف ساختار، آموزش شبکه عصبی بر اساس دیتاست  $D_{tr}$  شروع می‌شود و اعتبارسنجی آموزش نیز بر اساس دیتاست  $D_{val}$  انجام می‌شود. در صورتی که دقت اعتبار



شکل 1- فلوچارت الگوریتم پژوهش

Fig. 1- Research Flowchart

### 1-1- پیشینه تحقیق

شبکه عصبی مصنوعی یک روش محاسباتی در هوش مصنوعی است که از شبکه عصبی بیولوژیکی انسان الهام گرفته است (Haykin, 1994). مهمترین ویژگی‌های شبکه‌های عصبی مصنوعی را می‌توان در توانایی شبیه‌سازی توابع غیر خطی، تطابق پذیری، کار با داده‌های آموزشی و همچنین قابلیت تعمیم پذیری و پیش‌بینی شرایط بررسی کرد (Ranganayaki and Deepa, 2016). این ویژگی‌های شبکه عصبی مصنوعی باعث شده است که توجه پژوهشگران زیادی را به خود جلب کرده و در پیش‌بینی و حل مسأله‌های متعددی مورد استفاده قرار بگیرد. نکته مهم در شبکه‌های عصبی مصنوعی، فرآیند آموزش و ارائه تابع غیر خطی از طریق مشاهده داده‌های پیشین است. به این جهت شبکه‌های عصبی مصنوعی به دنبال کشف یک رابطه یا تابعی هستند که می‌تواند پارامترهای متغیر ورودی را به پاسخ نهایی تطبیق دهد. داده‌هایی که برای آموزش شبکه عصبی مصنوعی داده می‌شوند بدون بیان رابطه علت و معلولی، صرفاً به بیان پارامترهای متغیر و پاسخ حاصله می‌پردازند. به این داده‌ها، مجموعه داده‌های آموزشی و به فرآیند تقریب تابع از طریق بهینه سازی پارامترها بر اساس داده‌ها آموزشی، آموزش مدل شبکه عصبی گفته می‌شود.

در سال 1997 کامپیوتر دیپ بلو<sup>10</sup> شرکت آی بی ام<sup>11</sup> توانست برای اولین بار در تاریخ عصر دیجیتال، در مقابل قهرمان شطرنج (گری کاسپاروف) به پیروزی برسد (Newborn, 2012). این پیروزی، انقلابی در عرصه هوش مصنوعی به حساب می‌آمد و اهمیت الگوریتم‌های هوش مصنوعی را بیش از پیش بر همگان آشکار کرد. با آغاز سده 21 میلادی، پژوهشگران رشته‌های مختلف، از الگوریتم‌های هوش مصنوعی برای حل مسأله‌های خود استفاده کردند. همزمان در همین سال‌ها، استفاده از الگوریتم‌های هوش مصنوعی در حل مسأله‌های انرژی و ساختمان رشد فزاینده‌ای پیدا کرد (Kumar et al., 2013). اما یکی از نخستین نمونه‌های استفاده از الگوریتم شبکه عصبی مصنوعی در حوزه انرژی و پارامترهای پایداری، به سال 1993 و به پژوهش آنست بر می‌گردد.

آنست موضوع پیش‌بینی میزان مصرف انرژی در ساختمان‌ها با استفاده از الگوریتم شبکه عصبی مصنوعی را مطالعه کرد (Ansett, 1993). از زمان ارائه این تحقیق تا امروز، پژوهشگرهای متعددی در حوزه پیش‌بینی میزان مصرف انرژی با استفاده از شبکه‌های عصبی مصنوعی پژوهش کرده‌اند که هر کدام به مطالعه جنبه‌ای از قابلیت‌های شبکه‌های عصبی مصنوعی می‌پردازد (Curtiss et al., 1994, Kreider et al., 1995, Breekweg et al., 2000, Yalcintas and Akkurt, 2005, Neto and Fiorelli, 2008, Yu et al., 2011). مطالعه نتایج حاصل از این الگوریتم‌ها می‌تواند دقت متفاوت آنها را در پیش‌بینی پارامترهای پایداری و انرژی مشاهده کرد که این تفاوت تحت تأثیر ساختار متفاوت الگوریتم شبکه عصبی هر یک از این پژوهش‌هاست.

الگوریتم‌های شبکه عصبی مصنوعی در سایر حوزه‌های مطالعاتی مرتبط با پارامترهای پایداری محیطی نیز مورد استفاده قرار گرفته‌اند. تعدادی دیگر از پژوهشگران، از الگوریتم‌های شبکه عصبی مصنوعی در مطالعه پیش‌بینی سرعت جریان باد در محیط و ساختمان استفاده کرده‌اند (Ranganayaki and Deepa, 2016). گیپیل<sup>12</sup> از جمله پژوهشگران مطرح این حوزه است که بر پایه مطالعات خود، یک پلتفرم آنلاین پیش‌بینی سرعت باد راه اندازی کرده است (Giebel et al., 2011). جایراج<sup>13</sup> توانست با استفاده از شبکه عصبی مصنوعی، جریان و سرعت باد را در سه بازه زمانی 1 ساعت آینده، 24 ساعت آینده و 48 ساعت آینده پیش‌بینی کند (Jayaraj et al., 2004). تعدادی دیگر از پژوهشگران توانستند با استفاده از شبکه‌های عصبی بازگشتی<sup>14</sup>، سرعت و جریان باد را در بازه 72 ساعت آینده پیش‌بینی کنند (Barbounis et al., 2006). در سایر حوزه‌های پارامترهای پایداری نیز از شبکه‌های عصبی استفاده شده است. برای مثال در حوزه میزان نور روز دریافتی، وُنْگ<sup>15</sup> و همکارانش توانستند از شبکه‌های عصبی برای تحلیل و پیش‌بینی میزان نور دریافتی در فضاهای اداری استفاده کنند (Wong et al., 2010). پیش از آنها نیز گروهی از پژوهشگران معمار توانستند با برداشت محیطی میزان نور روز دریافتی در یک بازه 3 ماهه، داده‌های آموزشی شبکه عصبی را تهیه کنند و تابع مدل هوش مصنوعی را با دقت بالا تقریب بزنند



شکل 2- بافت شهری فرضی جهت شبیه سازی مقدار تابش دریافتی

Fig. 2- Sample Urban Context for simulation

فرم بافت شهری و ابعاد ارتفاع ساختمان‌های فرضی به گونه‌ای انتخاب شده است که مقادیر متنوعی از میزان انرژی تابشی دریافتی در نقاط مختلف سایت ایجاد شود. نتیجه این امر، پیچیده شدن تقریب تابع شبکه عصبی مصنوعی است که فرآیند حل این مسأله می‌تواند الهام‌بخش روش حل مسأله‌های مشابه در سایر پارامترهای پایداری محیطی باشد. بررسی میانگین میزان انرژی تابشی دریافتی در یک بازه زمانی در چنین بافت شهری، یک صفحه برازش<sup>16</sup> پیوسته‌ای را ایجاد می‌کند که دارای تابعی غیر خطی است. تقریب تابع غیر خطی که بتواند چنین صفحه برازشی را شبیه‌سازی کند مسأله پیچیده‌ای محسوب می‌شود که در این پژوهش سعی شده است با استفاده از تجربیات گذشته پژوهشگران و همچنین با آزمون و خطا ساختار مناسب شبکه عصبی با حداقل خطا پیشنهاد شود.

(Kazanasmaz et al., 2009). در حوزه میزان انرژی تابشی دریافتی نیز از قابلیت‌های شبکه عصبی مصنوعی استفاده شده است. گروهی از پژوهشگران دانشگاه تهران توانسته‌اند با استفاده از شبکه‌های عصبی مصنوعی میزان انرژی تابشی عمومی را پیش‌بینی کنند. مدل پیشنهادی این گروه مناسب فضاهایی است که قابلیت اندازه‌گیری محیطی با استفاده از ابزارها در آن امکان‌پذیر نباشد. در این پژوهش تمام پارامترهای آبهوایی به عنوان متغیر ورودی در داده‌های آموزشی در نظر گرفته شده است (Azadeh et al., 2009). پژوهش‌های ارائه شده تنها بخشی از ادبیات موضوعی این حوزه به شمار می‌آید و بیانگر اهمیت و دقت شبکه‌های عصبی مصنوعی در تحلیل و پیش‌بینی پارامترهای پایداری محیطی است. مقاله حاضر با تمرکز بر مطالعه کاربرد شبکه عصبی مصنوعی در تحلیل پارامترهای پایداری فضاهای شهری و معماری، به دنبال ارائه ساختار و راهکاری جهت استفاده از قابلیت‌های این الگوریتم در تحلیل‌ها و پیش‌بینی‌های معمارانه است. با توجه به اهمیت انرژی تابشی دریافتی در آسایش حرارتی محیط و همچنین میزان رشد گیاهان، تقریب تابع انرژی تابشی دریافتی در بافت شهری به عنوان نمونه مطالعاتی انتخاب شده است.


#### 2-1- تعریف مسأله

پژوهش حاضر به مطالعه میزان انرژی تابشی دریافتی در یک بافت شهری فرضی می‌پردازد. با توجه به وضعیت قرارگیری و ابعاد ساختمان‌ها، هر نقطه از بافت شهری دارای مقادیر انرژی تابشی متفاوتی است. این تفاوت مقادیر در نقاط همسایگی هر نقطه نیز دیده می‌شود که بیانگر پیچیدگی فضای شبیه‌سازی است. دلیل این امر میزان سایه دریافتی متفاوت هر نقطه در حوزه زمانی مطالعه است. در پژوهش حاضر، میانگین میزان تابش دریافتی بافت شهری در طول روز 1 دی ماه مورد بررسی قرار گرفته است.



ساخت مدل‌های ریاضیاتی بر پایه متغیرهای مستقل، مقادیر متغیرهای وابسته را پیش‌بینی کنند. در یادگیری بدون نظارت، فقط پارامترهای مستقل وجود دارد و اساسا پارامتر وابسته وجود ندارد. الگوریتم شبکه عصبی مصنوعی از جمله الگوریتم‌های پایه در یادگیری ماشینی است و با توجه به ساختار مسأله پژوهش حاضر، از نوع یادگیری با نظارت محسوب می‌شود که مستلزم دریافت مجموعه داده‌ها ورودی  $X$  *input* و خروجی  $y$  *output* جهت ارائه تابع برازش است. در ابتدا مدل بر اساس مجموعه داده‌های  $D_{tr}$  آموزش می‌بیند. آموزش مدل هوش مصنوعی یک فرآیند تکراری<sup>22</sup> است و به هر مرحله تکرار اپیاک<sup>23</sup> گفته می‌شود. تعداد اپیاک‌ها  $n_{epoch}$  از هاپرپارامترهایی<sup>24</sup> است که توسط پژوهشگر تنظیم می‌شود. در هر اپیاک، تمام داده‌های آموزشی به مدل شبکه عصبی داده شده و مدل سعی می‌کند با استفاده از روش‌های بهینه‌سازی گرادینتی<sup>25</sup> پارامترهای متغیر  $p_{tr}$  را طوری تنظیم کند که حداقل خطا  $loss$  ایجاد شود. پایین بودن مقدار خطا به تنهایی نشانگر موفقیت مدل آموزش دیده نیست. به این معنی که، مدل می‌تواند بر روی مجموعه داده‌های آموزشی، به درستی پارامتر وابسته را بر اساس پارامترهای مستقل پیش‌بینی کند اما احتمال دارد در داده‌های جدید پیش‌بینی اشتباه با خطای بالا انجام دهد. به این حالت، در ادبیات هوش مصنوعی بیش‌برازش<sup>26</sup> گفته می‌شود (Trevor et al., 2009). در چنین حالتی امکان تعمیم مدل به سایر داده‌های جدید وجود ندارد. در مقابل اگر میزان خطای  $loss$  بالا ننگه داشته شود تا مدل بیش‌برازش نشود امکان دارد که مدل دچار مشکل کم‌برازش<sup>27</sup> شود. در چنین وضعیتی، مدل توانایی پیش‌بینی درست هیچ یک از داده‌ها را ندارد.

با توجه به توضیحات بالا، ایجاد ساختاری که توانایی جلوگیری از بیش‌برازش و کم‌برازش را داشته باشد، اهمیت فراوانی دارد. بدین منظور مجموعه داده‌های اعتبارسنجی  $D_{val}$  تعریف می‌گردد که هدف آنها بیان میزان خطای داده‌های اعتبارسنجی  $loss_{val}$  در هر اپیاک است. برای کاهش خطای اعتبارسنجی، باید مقادیر هاپرپارامترها، تنظیم دقیق<sup>28</sup> شوند. در نهایت پس از



شکل 3- انرژی تابشی دریافتی نقاط دیتاست از طریق شبیه سازی قاعده‌محور. انجام محاسبات مقدار تابش دریافتی در گرسه‌پایر و افزونه لیدی باگ

Fig. 3- Radiation analysis on point dataset based on rule-based simulation. For the simulation, Ladybug add-on in Grasshopper 3D is used

## 2- روش تحقیق

پژوهش حاضر با استفاده از تکنیک‌های شبیه‌سازی نرم‌افزاری (شبکه عصبی مصنوعی) و روش آزمایشی به دنبال تقریب تابعی است که بتواند مشابه روش رگرسیون در تحقیق همبستگی روابط متغیرهای پیش‌بین و ملاک را پیدا کند. روش تحقیق حاضر مبتنی بر مدل‌سازی برازشی<sup>17</sup> است که مستقل از مطالعه قواعد حاکم در روابط بین پارامترهای ملاک و پیش‌بین، به دنبال یافتن تابعی غیر خطی است که می‌تواند با حداقل خطا پارامترهای وابسته را بر اساس پارامترهای مستقل پیش‌بینی کند. پارامترهای مستقل یا پیش‌بین این پژوهش، محل قرارگیری در بافت شهری است که یک مختصات محلی<sup>18</sup> با مقادیر عددی است. پارامتر وابسته یا ملاک این پژوهش، میانگین انرژی تابشی دریافتی در طول روز 1 دی ماه است.

## 3- نتایج و بحث

### 3-1- ساختار شبکه عصبی مصنوعی


یادگیری ماشینی<sup>19</sup> بر پایه مطالعه و تبیین ساختار الگوریتم‌هایی است که می‌توانند از طریق دریافت مجموعه داده‌ها، آموزش ببینند (Kohavi, 1998). یادگیری ماشینی بر پایه ساختار داده‌های آموزشی به دو دسته یادگیری با نظارت<sup>20</sup> و یادگیری بدون نظارت<sup>21</sup> تقسیم‌بندی می‌شود. الگوریتم‌های یادگیری با نظارت می‌توانند از طریق فرآیندهای داده محور و از طریق

$$A_i^j = fact \left[ \sum_{k=1}^{n_{ne}^{j-1}} w_{ki}^j * A_k^{j-1} + \theta_i \right]$$

$$j \in \{x | x \in N, 0 \leq x \leq n_{hl}\} \quad i \in \{x | x \in N, 0 \leq x \leq n_{ne}^j\}$$

فرمول 1- فرمول محاسبه مقادیر عددی هر نرون  
Eq. 1- The equation for each neuron

در فرمول بالا  $fact$  تابع فعال سازی<sup>30</sup> است و  $\theta_i^j$  ضریب تمایل<sup>31</sup> نرون  $i$  ام از لایه  $j$  ام است. توابع فعال سازی متفاوتی وجود دارد. در این پژوهش از تابع فعال سازی رلو<sup>32</sup> استفاده شده است. این تابع هر عدد منفی را به صفر نگاشت می کند و اعداد مثبت را بدون تغییر حفظ می کند (شکل 5). ضریب تمایل نیز یک پارامتر آموزش پذیر است که در فرآیند بهینه سازی هر اپیک تغییر می کند. این ضریب قابلیت تابع غیرخطی را افزایش داده و امکان جابجایی نمودار تابع را به مقدار مورد نظر ایجاد می کند. پس از محاسبه نرون های هر لایه، نهایتاً مقادیر پارامتر وابسته لایه خروجی  $\hat{y}$  محاسبه می شود. این پاسخ پیش بینی شده با پاسخ واقعی متفاوت است که اختلاف آنها ملاک تشخیص خطای  $loss$  محسوب می شود. در این پژوهش از فرمول خطای مربعی متوسط استفاده شده است (فرمول 2).




شکل 5- تابع فعال سازی رلو  
Fig. 5- ReLU activation function

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

فرمول 2- فرمول محاسبه خطای مربعی متوسط  
Eq. 2- Mean Square Error

پایان فرآیند آموزش، دقت نهایی مدل آموزش دیده بر اساس داده های  $D_{test}$  آزمایش می شود. در صورت مطلوب بودن نتایج، مدل ایجاد شده مناسب پیش بینی پارامتر وابسته بر اساس پارامترهای مستقل جدید است.



شکل 4- ساختار یک شبکه عصبی فرضی با دو لایه پنهان  
Fig. 4- A sample artificial neural network with 2 hidden layers

در شکل شماره 4، ساختار یک شبکه عصبی فرضی با دو لایه پنهان نمایش داده شده است. لایه ورودی دارای نرون های  $x_i$  است که بیانگر تعداد پارامترهای مستقل مسأله است. در نمونه مطالعاتی حاضر، مکان قرارگیری در بافت شهری که دارای دو مختصات  $x$  و  $y$  محلی است به عنوان نرون های ورودی  $x_1$  و  $x_2$  تعریف می شوند. در ادامه هر لایه پنهان  $hl_i$  دارای تعدادی نرون  $n_{ne}^i$  است که جزو هایپر پارامترهای قابل تغییر توسط پژوهشگر است. هر یک از نرون های یک لایه به تمامی نرون های لایه قبل متصل می شود و ساختار یک شبکه عصبی مصنوعی کاملاً متصل<sup>29</sup> را ایجاد می کند. بر روی هر یال اتصال دهنده یک عدد با نام وزن یال در نظر گرفته می شود. این اعداد در طی فرآیند تکراری آموزش، به گونه ای تغییر می کنند که پاسخ نهایی کمترین خطا را داشته باشد. آموزش شبکه عصبی مصنوعی، در اصل تنظیم مقادیر این وزن ها محسوب می شود. مقدار عددی نرون  $i$  ام لایه  $j$  ام با نام  $A_i^j$  معرفی می شود و از طریق فرمول 1 محاسبه می شود.



با توجه به مساحت بافت شهری مورد تحلیل که معادل 330 هزار متر مربع است، می توان به این نتیجه رسید که حدودا به ازای هر 18 متر مربع یک نقطه نمونه برداری وجود دارد. پس از آموزش شبکه عصبی مصنوعی به دنبال پیش بینی میانگین انرژی تابشی دریافتی نقاط جدید در سایت هستیم و توانایی مدل در تعمیم پذیری به نقاط جدید را مورد بررسی قرار می دهیم.

### 3-3- تعریف مدل های شبکه عصبی مصنوعی

برای تعریف ساختار شبکه عصبی مصنوعی، هایپر پارامترهای متعددی وجود دارد که باید پیش از شروع فرآیند آموزش، تنظیم شود. مقادیر تعداد لایه های پنهان، تعداد نورون های هر لایه، نوع الگوریتم بهینه سازی مدل، تابع فعال ساز هر لایه، تابع هزینه مدل، تعداد ایپاک ها و ابعاد دسته های<sup>42</sup> داده ها از نمونه های پارامترهای اصلی شبکه عصبی محسوب می شوند. ابعاد دسته ها به معنی تعداد داده هایی است که در هر فرآیند آموزش<sup>43</sup> به شبکه عصبی مصنوعی نشان داده می شود. در شبکه عصبی مصنوعی نمی توان تمام داده های را به یکبار به داخل شبکه وارد کرد و این امر نیازمند قدرت محاسباتی بالاست و ضمنا تابع شبکه را به سمت بیش برآزش شدن سوق می دهد. لذا مجموعه داده ها در قالب دسته هایی به داخل شبکه وارد می شوند. زمانی یک ایپاک به پایان می رسد که تمام داده ها در دسته های مشخص وارد شبکه شده باشند. ابعاد پایین دسته ها دقت محاسبات را کاهش می دهد و احتمال کم برآزشی را ایجاد می کند و ابعاد بالا دسته ها نیز قدرت محاسباتی بالا نیاز دارد و احتمال بیش برآزشی را ایجاد می کند.

2-3- مجموعه داده های آموزشی<sup>33</sup> مدل هوش مصنوعی همان طور که پیشتر اشاره شد، در پژوهش حاضر از روش شبیه سازی نرم افزاری برای تهیه دیتاست آموزشی استفاده شده است. در این راستا الگوریتم محاسبه انرژی تابش دریافتی<sup>34</sup> در نرم افزار راینو<sup>35</sup>، پلاگین گرسهاپر<sup>36</sup> و با استفاده از افزونه لیدی باگ<sup>37</sup> نوشته شده است. برای تهیه دیتاست مدل هوش مصنوعی، 30 هزار نقطه سایت نمونه برداری شده است. این مجموعه دیتاست شامل دیتاست آموزشی، اعتبارسنجی و آزمایشی می شود. پارامتر متغیر این نمونه ها، موقعیت قرارگیری در بافت شهری است که بر اساس مختصات محلی در راستای  $x$  و  $y$  محاسبه می شود. پاسخ حاصله، میانگین میزان تابش دریافتی در نقطه مذکور در طول روز 1 دی ماه است. میزان تابش دریافتی یک مقدار عددی و واحد آن  $\frac{kWh}{m^2}$  (کیلووات ساعت بر متر مربع) است. پس از تهیه مجموعه دیتاست، از کتابخانه تنسرفلو<sup>38</sup> و کراس<sup>39</sup> در زبان برنامه نویسی پایتون<sup>40</sup> برای شبیه سازی الگوریتم شبکه عصبی مصنوعی استفاده شده است.

در این پژوهش از تکنیک تفکیک داده ای<sup>41</sup> برای تهیه داده های آزمایشی استفاده شده است (Kohavi, 1995). بدین منظور 20 درصد از کل مجموعه داده ها به داده های آزمایشی و مابقی به داده های استفاده شده در فرآیند آموزشی اختصاص داده شده است. از 80 درصد باقی مانده نیز 20 درصد به مجموعه داده های اعتبارسنجی و 80 درصد آن به مجموعه داده های آموزشی اختصاص داده شده است (جدول 2). در تحلیل نهایی، 64 درصد از داده های اولیه برای آموزش شبکه عصبی مصنوعی استفاده شده است.

جدول 2- درصد و تعداد هر یک از مجموعه داده ها

Tab. 2- Training, Validation and Test Dataset

کل داده های استفاده شده در فرآیند آموزش (80 درصد کل)		
$D_{test}$ داده های آزمایش (20 درصد داده های کل)	$D_{val}$ داده های اعتبارسنجی (20 درصد داده های فرآیند آموزش)	$D_{tr}$ داده های آموزشی (80 درصد داده های فرآیند آموزش)
20%	16%	64%
5856	4685	18739
تعداد داده ها		مجموع داده ها
		29280

جدول 4- ساختار شبکه عصبی مصنوعی دوم

Tab. 4- Second ANN's architecture

Layer (Type)	Output Shape	Param #
Dense-1	(None, 80)	240
Dense-2	(None, 80)	6480
Dense-3	(None, 1)	81

Total param: 6,801  
Trainable params: 6,801  
Non-Trainable params: 0

جدول 5- ساختار شبکه عصبی مصنوعی سوم

Tab. 5- Third ANN's architecture

Layer (Type)	Output Shape	Param #
Dense-1	(None, 100)	300
Dense-2	(None, 100)	10100
Dense-3	(None, 100)	10100
Dense-4	(None, 100)	10100
Dense-5	(None, 100)	10100
Dense-6	(None, 100)	10100
Dense-7	(None, 100)	10100
Dense-8	(None, 1)	101

Total param: 61,001  
Trainable params: 61,001  
Non-Trainable params: 0

3-4- دقت پیش بینی مدل‌ها

پس از تکمیل فرآیند آموزش، می‌توان سه مدل شبکه عصبی را در دو حالت جداگانه مورد ارزیابی و تحلیل قرار داد. ابتدا وضعیت آنها در طول فرآیند آموزش و مقادیر توابع هزینه بر روی داده‌های آموزشی  $loss$  و اعتبارسنجی  $loss_{val}$  مورد بررسی قرار می‌گیرد. سپس دقت مدل در پیش‌بینی نقاط جدید سایت  $loss_{test}$  ارزیابی می‌شود. نتایج حاصل از آموزش هر سه مدل در تصاویر 9 و 10 ارائه شده است.

لذا تنظیم درست این ابعاد اهمیت ویژه‌ای دارد. در پژوهش حاضر، تعداد زیادی آزمایش بر اساس ساختارهای متنوع شبکه انجام شده و نتایج متفاوتی از آنها حاصل شده است. در مجموع می‌توان سه گروه متفاوت برای تعریف این شبکه‌ها مشاهده کرد. گروه اول، شبکه‌هایی هستند که سعی دارند با تعداد لایه‌های پایین و تعداد نورون‌های بالا به دنبال کشف تابع برازش باشند. نمونه انتخاب شده برای پژوهش حاضر یک لایه پنهان با 800 نورون است که در مجموع 3200 پارامتر قابل آموزش دارد (جدول 3). گروه دوم، شبکه‌هایی هستند که با تعداد لایه‌های متوسط و تعداد نورون‌های متوسط، تابع مسأله را تقریب می‌زنند. نمونه انتخاب شده برای این تحقیق، دو لایه پنهان 80 نورونی است که در مجموع 6801 پارامتر قابل آموزش دارد (جدول 4). گروه سوم، شبکه‌هایی هستند که با تعداد لایه زیاد و تعداد نورون‌های متوسط تابع مسأله را تقریب می‌زنند. نمونه انتخاب شده، هفت لایه پنهان 100 نورونی است که در مجموع 61001 پارامتر قابل آموزش ایجاد کرده است (جدول 5). در جدول شماره 6، هایپرپارامترهای هر سه مدل شبکه عصبی مصنوعی استفاده شده در این پژوهش ارائه شده است.

جدول 3- ساختار شبکه عصبی مصنوعی اول

Tab. 3- First ANN's architecture


Layer (Type)	Output Shape	Param #
Dense-1	(None, 800)	2400
Dense-2	(None, 1)	801

Total param: 3,201  
Trainable params: 3,201  
Non-Trainable params: 0

جدول 6- هایپرپارامترهای سه مدل شبکه عصبی مصنوعی

Tab. 6- ANN's hyper-parameters

مدل آموزشی سوم	مدل آموزشی دوم	مدل آموزشی اول	
7	2	1	$n_{hl}$ تعداد لایه های پنهان
(100,100,100,100,100,100,100)	(80,80)	(800)	$n_{ne}^i$ تعداد نرون‌های لایه‌ها
50	50	50	batch size ابعاد دسته داده‌ها
'adam'	'adam'	'adam'	optimizer الگوریتم بهینه‌ساز
'mean square error'	'mean square error'	'mean square error'	loss تابع هزینه
150	150	150	$n_{epoch}$ تعداد اپیاک
'relu'	'relu'	'relu'	fact تابع فعال ساز



شکل 7- نمودار تغییرات خطای  $loss_{val}$  و  $loss$  حاصل از آموزش مدل سوم



Fig. 7- Third model's training and validation loss

در ادامه دقت پیش‌بینی مدل‌ها بر روی داده‌های آزمایشی مورد بررسی قرار گرفت. در جدول شماره 7، اطلاعات کامل میزان خطای ثبت شده هر مدل ارائه شده است. همان‌طور که مشخص است، مدل شبکه عصبی سوم، خطای بسیار کمی را به ثبت رسانده است و توانسته است خطای پیش‌بینی مشابه خطای آموزش داشته باشد. اما دو مدل شبکه اول و دوم خطای بسیار زیادی را ثبت کرده‌اند و اختلاف زیادی با خطای آموزشی خود دارند.

جدول 7- خطاهای ثبت شده از مدل‌های آموزش دیده  
Tab. 7- Loss value for training, validation and training dataset

تابع هزینه داده‌های آزمایشی $loss_{test}$	تابع هزینه داده‌های اعتبارسنجی $loss_{val}$	تابع هزینه داده‌های آموزشی $loss$	
0.0297	0.0048	0.0052	مدل شبکه عصبی اول
0.0327	0.0024	0.0025	مدل شبکه عصبی دوم
0.0010	0.0010	0.0009	مدل شبکه عصبی سوم

مدل اول در پایان 150 اپیاک به کمترین خطای 0.0052 دست پیدا کرد. مدل دوم، خطای حداقلی 0.0025 را ثبت کرده است. مدل سوم با ثبت حداقل خطای 0.0009 در پایان 150 اپیاک، توانسته است بهترین عملکرد را در بین مدل‌های آموزش داده شده ارائه کند. نمودار آموزش مدل اول بیشترین نوسان بین خطای شبکه و خطای اعتبارسنجی را نشان می‌دهد. اختلاف زیاد بین خطای اعتبارسنجی و خطای مدل میزان اصلاحات مورد نیاز در هایپرپارامترها را اشاره می‌کند. مدل سوم هم نسبت به مدل اول و دوم با شیب بیشتری به سمت پاسخ بهینه حرکت کرده است. لذا در اپیاک شماره 20، مدل سوم به حدود خطای 0.002 دست پیدا کرده است که بهتر از پاسخ هر دو مدل دیگر در انتهای 150 اپیاک است.




شکل 6- نمودار تغییرات خطای  $loss_{val}$  و  $loss$  حاصل از آموزش مدل اول و دوم

Fig. 6- First and second model's training and validation loss

عصبی برای تقریب تابع استفاده شد. آزمایش‌های انجام شده نشان دادند که با تعریف درست هایپرپارامترها می‌توان با دقت بالا میانگین تابش دریافتی در نقاط جدید را پیش‌بینی کرد. مدل ارائه شده در این پژوهش، توانایی تعمیم‌پذیری به مسأله‌های مشابه را دارد و الگو پژوهشی ارائه شده را می‌توان در سایر موضوعات معماری نیز مورد استفاده قرار داد.

**پی‌نوشت**

- 1 Data-driven process
- 2 Training Dataset
- 3 Surrogate Modelling
- 4 Local coordinates
- 5 Dataset
- 6 Training Dataset
- 7 Validation Dataset
- 8 Test Dataset
- 9 Number of Layers
- 10 Number of neurons
- 11 Fine tuning
- 12 Deep Blue
- 13 IBM
- 14 Giebel
- 15 Jayaraj
- 16 Recurrent Neural Networks (RNN)
- 17 Wong
- 18 Fitness Landscape
- 19 Machine Learning
- 20 Supervised Learning
- 21 Unsupervised Learning
- 22 Iterative
- 23 Epoch
- 24 Hyper-parameter
- 25 Gradient based optimization
- 26 Overfitting
- 27 Under fitting
- 28 Fine tuning
- 29 Fully connected
- 30 Activation Function
- 31 Bias
- 32 Relu
- 33 Dataset
- 34 Solar Radiation (Insolation)
- 35 Rhinoceros Software
- 36 Grasshopper3D
- 37 Ladybug and Honeybee
- 38 Tensor Flow
- 39 Keras
- 40 Python
- 41 Holdout method
- 42 Batch size
- 43 Iteration
- 44 Manifold



شکل 8- مقایسه میزان خطا سه مدل در پیش‌بینی 10 نمونه از داده‌های آزمایشی

**Fig. 8- Loss value comparison of three trained model**

شکل شماره 8، نمودار مقایسه میزان خطای محاسباتی سه مدل آموزش دیده در پیش‌بینی میانگین انرژی تابشی در 10 نقطه جدید از سایت را نمایش می‌دهد. همان‌طور که مشخص است، دقت پاسخ مدل سوم از همه بیشتر است و کمترین خطا را دارد. علت این موضوع را می‌توان در پیچیدگی فضای جستجو و منیفولد<sup>44</sup> برازش بررسی کرد. به دلیل پیچیدگی پاسخ‌ها و تنوع آنها در هر ناحیه، نیاز به یک شبکه عصبی با پیچیدگی بالا است تا بتواند فضای جستجو پیچیده را با دقت بالا شبیه‌سازی کند. باید دقت داشت که پیچیده‌تر کردن شبکه عصبی منجر به ایجاد مشکل بیش‌برازش می‌شود و لزوماً به سمت بهبود مدل بهینه‌تر حرکت نمی‌کند. لذا حد مطلوب پیچیدگی از طریق آزمایش قابل حصول است.

**4- نتیجه‌گیری**

شبکه‌های عصبی مصنوعی یکی از الگوریتم‌های پایه و مهم در هوش مصنوعی به شمار می‌رود. از شبکه‌های عصبی مصنوعی در حل طیف وسیعی از مسأله‌ها استفاده می‌شود. یکی از کاربردهای آن در تقریب تابع رگرسیونی است که می‌تواند مستقل از روابط علت و معلولی، مقادیر عددی متغیرهای وابسته را بر اساس مقادیر متغیرهای مستقل محاسبه کند. پژوهش ارائه شده در این مقاله، تجربه شبیه‌سازی تابع میانگین انرژی تابشی دریافتی در طول روز یک دی ماه در یک بافت شهری فرضی در تهران را ارائه کرد. از مدل‌های هوش مصنوعی شبکه



Kohavi, R. 1998. Glossary of terms. Special issue on applications of machine learning and the knowledge discovery process, 30, 127-132.

Kreider, J., Claridge, D., Curtiss, P., Dodier, R., Haberl, J. and Krarti, M. 1995. Building energy use prediction and system identification using recurrent neural networks. *Journal of solar energy engineering*, 117, 161-166.

Kumar, R., Aggarwal, R. and Sharma, J. 2013. Energy analysis of a building using artificial neural network: A review. *Energy and Buildings*, 65, 352-358.

MahdaviNejad, M. and Javanroodi, K. 2016. Impact of roof shape on air pressure, wind flow and indoor temperature of residential buildings. *International Journal of Sustainable Building Technology and Urban Development*, 7, 87-103.

MahdaviNejad, M. and Nzar, N. S. 2017. Daylightophil High-Performance Architecture: Multi-Objective Optimization of Energy Efficiency and Daylight Availability in BSK Climate. *Energy Procedia*, 115, 92-101.

Neto, A. H. and Florelli, F. A. S. 2008. Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. *Energy and buildings*, 40, 2169-2176.

NewBorn, M. 2012. *Kasparov versus Deep Blue: Computer chess comes of age*, Springer Science and Business Media.

Rangannayaki, V. and Deepa, S. 2016. An intelligent ensemble neural network model for wind speed prediction in renewable energy systems. *The Scientific World Journal*, 2016.

Talaei, M., MahdaviNejad, M., Zarkesh, A. and Haghghi, H. M. 2017. A Review on Interaction of Innovative Building Envelope Technologies and Solar Energy Gain. *Energy Procedia*, 141, 24-28.

Trevor, H., Robert, T. and JH, F. 2009. *The elements of statistical learning: data mining, inference, and prediction*. New York, NY: Springer.

Wong, S. L., Wan, K. K. and Lam, T. N. 2010. Artificial neural networks for energy analysis of office buildings with daylighting. *Applied Energy*, 87, 551-557.

## منابع

Ansett, M. 1993. Application of neural networking models to predict energy use. *ASHRAE transactions*, 99, 505-517.

Azadeh, A., Maghsoudi, A. and Sohrabkhani, S. 2009. An integrated artificial neural networks approach for predicting global radiation. *Energy Conversion and Management*, 50, 1497-1505.

Barbounis, T. G., Theocharis, J. B., Alexiadis, M. C. and Dokopoulos, P. S. 2006. Long-term wind speed and power forecasting using local recurrent neural network models. *IEEE Transactions on Energy Conversion*, 21, 273-284.

Brekweg, M. R., Gruber, P. and Osman, A. 2000. Development of a generalized neural network model to detect faults in building energy performance--part II/Discussion. *Ashrae Transactions*, 106, 74.

Curtiss, P., Brandemuehl, M. and Kreider, J. 1994. Energy management in central HVAC plants using neural networks. *ASHRAE Transactions*, 100, 476-493.

Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M. and Draxl, C. 2011. The state-of-the-art in short-term prediction of wind power: A literature overview. *Anemos*. plus.

Haykin, S. 1994. *Neural networks: a comprehensive foundation*, Prentice Hall PTR.

Javanroodi, K., MahdaviNejad, M. and Nik, V. M. 2018. Impacts of urban morphology on reducing cooling load and increasing ventilation potential in hot-arid climate. *Applied Energy*, 231, 714-746.

Jayaraj, S., Padamakumari, K., Sreevalsan, E. and Arun, P. Wind speed and power prediction using artificial neural networks. *European wind energy conference*, 2004.

Kazanasmaz, T., Gunaydin, M. and Binol, S. 2009. Artificial neural networks to predict daylight illuminance in office buildings. *Building and Environment*, 44, 1751-1757.

Kohavi, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai*, 1995. Montreal, Canada, 1137-1145.

Yu, W., LI, B., Lei, Y. and Liu, M. 2011. Analysis of a residential building energy consumption demand model. *Energies*, 4, 475-487.

Yalcintas, M. and Akkurt, S. 2005. Artificial neural networks applications in building energy predictions and a case study for tropical climates. *International journal of energy research*, 29, 891-901.



سال، هجتم، شماره دوم، پاییز و زمستان 98

