

# پیش‌بینی بزرگای زلزله با استفاده از شبکه عصبی پرسپترون چندلایه

محمد علی ارجمند<sup>۱</sup>، جمال محمودی<sup>۲\*</sup>، مسعود رضائی<sup>۳</sup>، محمد حسین محمدی<sup>۴</sup>

۱- استادیار دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجایی

۲- دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه خواجه نصیرالدین طوسی

۳- دانشجوی کارشناسی ارشد، دانشکده مهندسی زلزله، مرکز تحقیقات راه، مسکن و شهرسازی

۴- دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه خوارزمی

[jmahmoudi@mail.kntu.ac.ir](mailto:jmahmoudi@mail.kntu.ac.ir)

تاریخ پذیرش: [۱۳۹۴/۱۰/۲۷]

تاریخ دریافت: [۱۳۹۴/۲/۱۱]

**چکیده** - به دلیل نواقص موجود در روش‌های پیشین محاسبه بزرگای زلزله، شبکه عصبی به عنوان یک روش جدید برای این منظور آزمایش می‌شود. در این مقاله نوعی شبکه عصبی با نام پرسپترون چندلایه برای پیش‌بینی بزرگای زلزله استفاده شده قرار گرفته است. شبکه عصبی پرسپترون شامل سه لایه اصلی با نام‌های لایه ورودی، لایه پنهان و لایه خروجی است. ورودی‌های این شبکه شش متغیر مربوط به مکان و زمان وقوع زلزله و همچنین مشخصات گسل تولید کننده زلزله است و خروجی آن همان بزرگای زلزله است. از آن جا که بهترین تنظیمات شبکه همچون بهترین تعداد گره‌های لایه پنهان و مناسب ترین شیوه آموزشی شبکه از پیش قابل تعیین نیستند و همچنین امکان یادگیری زائد در تکرارهای بعدی ممکن است، در این پژوهش ۳۲ مدل از شبکه با تنظیمات مختلف به کار گرفته شده است تا بهترین مدل شناسایی شود. با توجه به نتایج حاصل از شبکه و مقایسه نتایج با مقادیر حقیقی، مشخص می‌شود که شبکه عصبی پرسپترون چند لایه توانایی بالایی در پیش‌بینی بزرگای زلزله دارد و گزینه بسیار مناسبی برای این منظور است.

**واژگان کلیدی:** پرسپترون چند لایه، شبکه عصبی، بزرگای زلزله، پیش‌بینی، شیوه‌های آموزش شبکه

## ۱- مقدمه

تجربی در این خصوص شده است. این در حالی است که استفاده از این معادلات برای محاسبه و پیش‌بینی زلزله تحت تاثیر پارامترهای زیادی است. بسیاری از این پارامترها باید به دقت اندازه‌گیری شده و در معادلات وارد شود، در حالی که در بسیاری از مناطق، به دلیل کمبود ابزار و تجهیزات، این پارامترها به صورت تقریبی اندازه‌گیری می‌شوند و حتی گاهی مقادیری فرضی برای آن‌ها در نظر گرفته می‌شود. همچنین برخی پارامترهای این معادلات از قبیل مشخصات فیزیکی گسل‌ها دارای دشواری‌هایی در اندازه‌گیری است. به عنوان نمونه نرخ کرنش گسل بدون وجود علایم ظاهری در سطح زمین غیر قابل اندازه‌گیری است. همچنین این معادلات

از زمان‌های قدیم و در پی حوادث و وقایع طبیعی، بشر همواره به دنبال راهکارهایی برای جلوگیری یا کنترل این وقایع بوده است. زلزله یکی از این حوادث طبیعی است که وقوع آن همواره تلفات جانی و مالی سنگینی به همراه داشته است. زمان، مکان و بزرگای زلزله سه پارامتر اصلی زلزله هستند که برای کنترل و کمینه نمودن تلفات آن باید برآورد خوبی از مقادیر آن‌ها در دست باشد. از این رو دانشمندان و پژوهشگران تلاش‌های موفق و ناموفق بسیاری را برای یافتن رابطه‌ای بین این سه پارامتر و یا برآورد مناسبی از آن‌ها صورت داده‌اند. عموماً این تلاش‌ها منجر به تولید و ارائه روابطی تئوری و

## ۲- مدل سازی شبکه عصبی پرسپترون چند لایه

شبکه‌های عصبی پرسپترون از چندین لایه از گره‌ها شامل یک لایه ورودی، یک لایه خروجی و یک (یا چند) لایه پنهان تشکیل شده است که هر کدام از این لایه‌ها به ترتیب شامل گره‌های ورودی (گره‌های حسی)، گره‌های خروجی (گره‌های پاسخ دهنده) و گره پنهان است. یک نمونه شماتیک از شبکه عصبی پرسپترون چند لایه در شکل (۱) نشان داده شده است.

شکل (۱) طرحی ساده از شبکه عصبی پرسپترون چند لایه




Fig. 1. Simple schematic of multilayer perceptron neural network

شبکه عصبی استفاده شده در این پژوهش از یک لایه پنهان تشکیل شده است که این لایه پنهان نیز خود از گره‌های غیرقابل مشاهده‌ای تشکیل شده است. هر گره پنهان تابعی از جمع وزن‌دهی شده ورودی‌هاست. تابع مورد استفاده، تابع فعال سازی نام دارد و ارزش وزنی اختصاص داده شده به وسیله‌ی الگوریتم تخمین تعیین می‌شود. تابع فعال‌سازی هایپربولیک تانژانتی برای لایه پنهان استفاده شده است. این تابع مقادیر واقعی را می‌گیرد و آن را به محدوده (۱, -۱) انتقال می‌دهد.

$$\gamma(c) = \tanh(c) = \frac{e^c - e^{-c}}{e^c + e^{-c}} \quad (1)$$

برای لایه خروجی از تابع فعال‌سازی سافت ماکس استفاده شده است. که این تابع برداری از مقادیر واقعی را می‌گیرد و آن را به برداری دیگر انتقال می‌دهد، به گونه‌ای که مولفه‌هایش در محدوده‌ی (۰, ۱) است و مجموعشان برابر ۱ می‌شود.

اغلب برای نقاط خاصی از جهان است و غیر قابل استفاده برای نقاط دیگرند.

از سوی دیگر شبکه عصبی به عنوان یکی از قدرتمندترین ابزارها در مدل‌سازی و پیش‌بینی خود را به اثبات رسانده است. شبکه‌های عصبی سه مزیت عمده دارند: اول اینکه شبکه‌های عصبی توانایی یادگیری هر گونه محیط پیچیده و غیرخطی را دارند. دوم اینکه شبکه هیچ‌گونه پیش‌فرضی در مورد توزیع داده‌ها نمی‌کند و سوم اینکه شبکه‌های عصبی در برابر داده‌های ناقص و از دست رفته بسیار انعطاف پذیر است، پس نگرانی در این مورد را از بین می‌برند (ولیدو و همکاران [۱]). علاوه بر این، شبکه‌های عصبی قابل استفاده در هر منطقه‌ای است و به عنوان راه حلی کلی شناخته می‌شوند.

شبکه عصبی عملکرد موفقی در حل و تشخیص الگوهای پیچیده و مسایل طبقه‌بندی شده داشته است و در حوزه‌های مختلفی مانند تشخیص گفتار (یو دلبیو سی و همکاران [۲])، پردازش سیگنال‌ها (سیکوکی و زان [۳])، مهندسی پزشکی و تشخیص پزشکی (عادلی و همکاران [۴])، مهندسی ساخت (سنوسی و عادلی [۵])، مهندسی حمل و نقل (سایچنیک [۶])، شبکه‌های کامپیوتری (کیمورا و ایگر گوشی [۷]) و پیش‌بینی‌های مالی (چی فونگ و یین جیون [۸]) مورد استفاده قرار گرفته است.

به دلیل پیشینه رضایت بخش شبکه در پیش‌بینی گسترده‌ی بزرگی از پارامترها در رشته‌های گوناگون که به طور مختصر به آن‌ها اشاره شد، انتظار می‌رود که به کمک شبکه عصبی بتوان بزرگای گشتاوری زلزله (که از این پس به اختصار بزرگای زلزله خوانده می‌شود) را به خوبی پیش‌بینی نمود.

با توجه به آنچه که بیان شد، نوعی از شبکه عصبی به نام شبکه پرسپترون چند لایه (MLP)، که به عنوان یکی از موثرترین مدل‌ها در زمینه پیش‌بینی شناخته شده است، برای پیش‌بینی بزرگای زلزله استفاده شده و نتایج آن در ادامه ارائه شده است. در بخش دوم شبکه عصبی پرسپترون چند لایه توصیف شده است. در بخش سوم پارامترهای استفاده شده در مدل‌ها تعریف شده‌اند و نتایج پیش‌بینی شبکه در بخش چهارم مورد بحث قرار گرفته است.

علاوه بر این، در بخش آموزش نیز به منظور رسیدن به نتایج جامع‌تر، از دو روش دسته‌ای و برخط استفاده می‌شود. پس، در این پژوهش ۳۲ گروه مختلف از پارامترها و در نتیجه آن ۳۲ مدل شبکه مطابق جدول (۱) تشکیل می‌شود.

جدول (۱) مدل‌های مختلف شبکه عصبی پرسپترون چند لایه به کار رفته در پژوهش

32 Models		Number of nodes in hidden layer			
Training method	epochs	8	12	16	20
Batch	1	N081	N121	N161	N201
	2	N082	N122	N162	N202
	4	N084	N124	N164	N204
	8	N088	N128	N168	N208
Online	1	N081	N121	N161	N201
	2	N082	N122	N162	N202
	4	N084	N124	N164	N204
	8	N088	N128	N168	N208

Table 1. Different models of MLP neural network which is used in the current study

### ۳- توضیح متغیرهای ورودی و خروجی

اطلاعات لرزه‌ای استفاده شده در این پژوهش تمامی زلزله‌های ثبت شده دستگاهی در محدوده‌ی ایران خواهد بود که در پایگاه اطلاعاتی پژوهشگاه بین‌المللی زلزله‌شناسی و مهندسی زلزله موجود است [۱۰]. در مجموع حدود ۱۷۰۰۰ زلزله‌ی ثبت شده در گستره‌ی ایران گردآوری شد که پس از اصلاح کاتالوگ و حذف پیش‌لرزه‌ها و پس‌لرزه‌ها (که روش انجام آن جلوتر بیان خواهد شد) در حدود ۱۱۰۰۰ زلزله باقی ماند. از آن جا که در بحث مهندسی سازه زلزله‌های بزرگتر از ۴ ریشتر اهمیت دارد، زلزله‌هایی با بزرگای کوچکتر از ۴ ریشتر نیز از میان داده‌ها کنار گذاشته شدند. در راستای یادگیری بهتر شبکه عصبی، مناطق و گسل‌های که کمتر از ۳ زلزله برای آن‌ها ثبت شده بود از مجموع داده‌ها حذف شده‌اند و در پایان ۴۰۹۸ زلزله برای استفاده در پژوهش به کار گرفته شده است. برای هر زلزله ۷ پارامتر تعریف شد که ۶ پارامتر آن متغیرهای ورودی (مستقل) و یک پارامتر متغیر خروجی (وابسته) است. همان‌گونه که پیشتر نیز بیان شد، متغیرهای ورودی شامل سه متغیر مربوط به مکان وقوع زلزله، یک متغیر زمانی و دو متغیر مربوط به مشخصات فیزیکی و

$$\gamma(c_k) = \exp(c_k) / \sum_j \exp(c_k) \quad (2)$$

روش‌های آموزش: روش آموزشی بیانگر چگونگی پردازش شبکه روی داده‌های ورودی است. سه روش متداول آموزشی به شرح زیر است:

روش دسته‌ای: در این روش ضرایب تعدیل (وزن‌های سیناپسی) هر بار پس از بررسی کامل داده‌های یک دوره آموزشی بروزرسانی می‌شوند. ارجحیت این روش آموزشی برای آن است که شبکه در این روش خطاهای کلی را حداقل می‌سازد. با توجه به اینکه شبکه تا زمانی که به یکی از ضوابط توقف نرسیده باشد باید چندین بار تمامی داده‌ها را بررسی کند تا ضرایب را بروز رسانی نماید، پس این روش برای بانک‌های اطلاعاتی کوچک مناسبتر است.

روش برخط: در این روش با هر بار بررسی یک داده، ضرایب تعدیل بروز رسانی می‌شود. به عبارت دیگر تا زمانی که شبکه به یکی از ضوابط توقف خود نرسیده باشد، به تعداد داده‌های بررسی شده ضرایب تعدیل بروز رسانی می‌شود. این روش در خصوص بانک‌های اطلاعاتی حجیم نسبت به روش دسته‌ای ارجحیت دارد [۹].

گره‌های ورودی بر پایه متغیرهای ورودی بنا می‌شوند. در این پژوهش، شش متغیر مستقل شامل سه متغیر مکانی (عرض جغرافیایی، طول جغرافیایی، عمق)، یک متغیر زمانی (روز) و دو متغیر مربوط به ویژگی‌های فیزیکی (نوع خاک، سازوکار گسل) تعریف شده است. گره‌های خروجی شبکه‌های عصبی نتایج پیش‌بینی و در واقع همان بزرگای زلزله است که در چهار سطح طبقه‌بندی شده‌اند.

در لایه پنهان، به این دلیل که هیچ روشی برای یافتن تعداد گره‌های پنهان بهینه به طور مستقیم و از پیش وجود ندارد، چهار مقدار مختلف برای تعداد گره‌های پنهان شامل ۸، ۱۲، ۱۶ و ۲۰ انتخاب شده است. علاوه بر این، یک نگرانی شناخته شده در مورد شبکه‌های عصبی "آموزش زائد" آن است. برای کاهش این مشکل آموزش را می‌توان به طور مستمر به وسیله‌ی پارامترهای مختلف انجام داد. بنابراین، از چهار دوره آموزش مختلف، شامل ۱، ۲، ۴ و ۸ دوره آموزش استفاده می‌شود.

منطقه این پارامتر قابل اندازه‌گیری نبود پس عددی پیش‌فرض برای متغیر زمانی این زلزله‌ها انتخاب شد. مبنای انتخاب این عدد پیش‌فرض برای یک زلزله میانگین‌گیری از متغیر زمانی زلزله‌های دیگر با بزرگای مشابه بود.

- نوع خاک: نوع خاک مناطق وقوع زلزله براساس آیین‌نامه زلزله ایران در چهار طبقه دسته‌بندی شد [۱۴].

- سازوکار عملکردی گسل‌ها: گسل‌ها براساس سازوکار عملکردی در ۸ دسته قرار می‌گیرند: نرمال، معکوس، برشی راست‌گرد، برشی چپ‌گرد، نرمال - برشی چپ‌گرد، نرمال - برشی راست‌گرد، معکوس - برشی راست‌گرد و معکوس - برشی چپ‌گرد.

متغیر خروجی:

متغیر خروجی نیز همان بزرگای زلزله‌های رخ داده است که هدف این پژوهش پیش‌بینی آن است. لازم به گفتن است که این پارامتر به صورت یک متغیر کیفی (نه کمی) در ۴ دسته تقسیم بندی شده و به هر زلزله اختصاص داده شده است. این کار برای افزایش توانایی پیش‌بینی شبکه عصبی است، چرا که این شبکه‌ها با خروجی‌های کیفی و طبقه‌بندی شده بسیار سازگارترند. طبقه‌بندی بزرگای زلزله را در جدول (۲) مشاهده می‌کنید.

جدول (۲) طبقه‌بندی بزرگای زلزله

A	B	C	D
4-5	5-6	6-7	Bigger than 7

Table 2. Earthquake magnitude classification

انتخاب داده‌های فازهای مختلف شبکه عصبی، تصادفی صورت می‌پذیرد اما با توجه به اندک بودن تعداد زلزله‌های بزرگتر از ۶ و ۷ ریشتر که به ترتیب طبقه‌های C و D را در این مقاله تشکیل می‌دهند، لازم است تا محدودیت‌هایی نیز برای انتخاب داده تعیین شود تا بتوانیم در هر سه فاز داده‌هایی از دو طبقه گفته شده داشته باشیم. اساس انتخاب کاتالوگ‌های آموزش، تست و پیش‌بینی در این مقاله نیز به همین شیوه بوده است. از مجموع ورودی‌ها ۸۵ درصد آن برای آموزش شبکه و ۱۰ درصد آن برای آزمایش شبکه و اصلاح آن و ۵ درصد باقی مانده برای پیش‌بینی بزرگای زلزله به وسیله شبکه اختصاص داده شد. سپس این پیش‌بینی‌ها با مقادیر واقعی بزرگا مقایسه شد تا توانایی پیش‌بینی

عملکردی گسل‌ها (شامل نوع خاک و سازوکار عملکردی گسل‌ها) است.

ابتدا شیوه اصلاح کاتالوگ بیان می‌شود و سپس متغیرها به تفکیک توضیح داده می‌شوند:

اصلاح کاتالوگ (حذف پیش‌لرزه‌ها و پس‌لرزه‌ها):

تا به حال روش‌های زیادی برای حذف لرزه‌های وابسته (پس‌لرزه‌ها و پیش‌لرزه‌های) پیشنهاد شده است. با این وجود، بیشتر کاربران الگوریتم‌های پیشنهاد شده به وسیله‌ی گاردنر و نویوف [۱۱]، ریزنبرگ [۱۲] و اورهامر [۱۳] را به دلیل سادگی و سهولت این الگوریتم‌ها و در دسترس بودن کدهای کامپیوتری آن‌ها، ترجیح داده و به کار می‌گیرند.

در این مطالعه، روش اصلاح کاتالوگ اورهامر به کار گرفته شده است. در این روش با توجه به بزرگای زلزله رخ داده، حد زمانی و مکانی وقوع لرزه‌های وابسته با استفاده از روابط ۳ و ۴ تعیین می‌شود. چنانچه لرزه‌ای با بزرگای کمتر در هر دو محدوده زمانی و مکانی از لرزه‌ای با بزرگای بیشتر قرار گیرد، اگر پیش از لرزه‌ی بزرگتر رخ داده باشد، پیش‌لرزه است و چنانچه پس از آن رخ داده باشد، پس‌لرزه محسوب می‌شود.

$$d = e^{-1.024+0.84*M} \quad (3)$$

$$t = e^{-2.89+1.235*M} \quad (4)$$

در این روابط M بزرگای زلزله، d معیار فاصله مکانی برحسب کیلومتر و t معیار فاصله زمانی برحسب روز است.

متغیرهای ورودی:

- متغیر مکانی: طول و عرض جغرافیایی و عمق وقوع زلزله سه پارامتر مکانی‌ای است که به هر زلزله اختصاص داده شده است. برای زلزله‌های با عمق نامشخص عمق ۳۳ کیلومتر فرض شده است.

- متغیر زمانی: این متغیر برای هر زلزله معرف اختلاف زمانی وقوع آن از زلزله قبلی رخ داده در آن گسل در واحد زمانی روز است. این پارامتر به نوعی معرف انرژی ذخیره شده در گسل‌ها نیز است. لازم به گفتن است که این پارامتر پیش از حذف زلزله‌های با بزرگای کمتر از ۴ ریشتر اندازه‌گیری شده است، چراکه با وقوع این زلزله‌ها بخشی از انرژی ذخیره شده در گسل آزاد می‌شود. با توجه به اینکه برای اولین زلزله ثبت شده در هر

شبکه ارزیابی شود.

#### ۴- نتایج و بحث

همان گونه که در شکل (۲) دیده می شود، متوسط پیش بینی صحیح مدل ها در حدود ۷۰٪ است. از نتایج مشخص می شود که هر دو روش آموزش برخط و دسته ای توانایی خوبی در پیش بینی دارند اما شبکه با استفاده از روش آموزش برخط دارای قدرت پیش بینی بالاتری است و شاید دلیل این امر این است که مجموعه داده بزرگی در این پژوهش استفاده شده گرفته است.

همچنین، با توجه به نتایج، مدل ها با ۱۶ گره در لایه پنهان دارای بالاترین درصد پیش بینی صحیح است، بنابراین می توان نتیجه گرفت که تعداد گره های بهینه در لایه پنهان ۱۶ گره است. علاوه بر این، در مورد تعداد دوره های آموزشی، نتایج نشان می دهد که بیشتر مدل ها بهترین آموزش را در همان اولین دوره یادگیری کسب نموده اند. به شکل کلی، بهترین پیش بینی، پیش بینی انجام شده به وسیله مدل N161 و با استفاده از روش آموزشی برخط به میزان ۷۳/۱ درصد است.

خروجی دیگر شبکه ضرایب اهمیت متغیرهای مستقل است. این ضرایب تاثیر هر یک از متغیرهای مستقل در بزرگای زلزله را نشان می دهد. ضرایب اهمیت متغیرها در مدل N161 با شیوه آموزشی برخط در جدول (۳) نشان داده شده است. همان گونه که در این جدول، و نیز جدول مشابه سایر مدل ها، دیده می شود،

متغیر زمان (روز) بالاترین تاثیر را در بزرگای زلزله داشته است. پس از متغیر زمان، متغیرهای مکانی بیش ترین تاثیر را داشته اند و در بین تمام متغیرهای استفاده شده، نوع خاک منطقه کمترین تاثیر را بر روی مقدار بزرگای زلزله ها داشته است.

جدول (۳) پیش بینی های صورت گرفته به وسیله ی

Variables	Impact Factor	Normalized Impact Factor
Long.	0.2	94.40%
Lat.	0.197	93.20%
Depth	0.185	87.50%
Days	0.211	100%
Soil Type	0.064	30.30%
Fault Mechanism	0.143	67.70%

Table 3. Impact factor of input variables

جدول ۴ پیش بینی های صورت گرفته توسط مدل N162 با شیوه آموزشی دسته ای را در سطوح مختلف بزرگا در فرایندهای آموزش شبکه، آزمایش شبکه و پیش بینی شبکه به تفکیک نمایش می دهد (مدل انتخابی با ۷۰/۶ درصد پیش بینی صحیح بالاترین درصد پیش بینی صحیح را در بین مدل ها با شیوه آموزشی دسته ای داشته است).

شکل (۲) درصد پیش بینی صحیح مدل ها




Figure 2. Models correct prediction percentage

جدول (۴) پیش‌بینی‌های صورت گرفته به وسیله‌ی مدل N162 با شیوه آموزشی دسته‌ای

Classification						
Sample	Observed	Predicted				Correct (%)
		A	B	C	D	
Training	A	2122	208	1	0	91.03
	B	794	217	1	0	21.44
	C	89	22	3	0	2.63
	D	0	1	2	0	25
	Overall Percent	86.62	12.94	0.20	0.03	67.70
Validation	A	221	40	0	0	84.67
	B	68	47	0	0	40.87
	C	5	7	2	1	13.33
	D	0	1	1	1	100
	Overall Percent	75	23.98	0.51	0.51	69.10
Testing	A	136	33	1	0	80
	B	30	34	2	0	51.52
	C	2	1	2	1	33.33
	D	0	1	1	1	33.33
	Overall Percent	68.57	28.16	2.45	0.82	70.60

Table 4. Predictions done by model N162 with batch training method

نکته حائز اهمیت دیگر این است که در تمامی سطوح بزرگا، حتی در مواردی که پیش‌بینی صورت گرفته صحیح نبوده‌است، بیشتر بزرگاها یا یک طبقه بالاتر و یا یک طبقه پایین‌تر از طبقه واقعی پیش‌بینی شده‌اند و پیش‌بینی‌ها به مقادیر بزرگای واقعی نزدیک بوده‌اند.

## ۵- نتیجه‌گیری

در این مقاله به موضوع پیش‌بینی بزرگای زلزله آینده با استفاده از پیدا کردن الگو، به وسیله‌ی شبکه عصبی، در زمین‌لرزه‌های گذشته پرداخته شده است.

بر اساس نتایج و خروجی‌ها، ملاحظه می‌شود که شبکه عصبی پرسپترون چند لایه ابزاری کارآمد در پیش‌بینی بزرگای زلزله در یک منطقه برای زمانی دلخواه است. میانگین پیش‌بینی صحیح مدل‌ها در حدود ۷۰ درصد بود. نتایج آشکار ساخت که هر دو روش دسته‌ای و برخط توانایی بالایی در پیش‌بینی بزرگا داشتند، اگرچه در مطالعه فعلی شبکه عصبی چند لایه با روش آموزشی برخط کمی نتایج بهتری از خود نشان داد. همچنین، بر اساس خروجی‌ها مشخص شد که تعداد گره‌های بهینه در لایه پنهان برابر ۱۶ گره است. در خصوص تعداد دوره نتایج نشان می‌دهد که بیشتر مدل‌ها بهترین عملکرد خود را با یک دوره یادگیری داشتند. با توجه به ضرایب اهمیت متغیرهای شبکه عصبی پرسپترون چند لایه می‌توان گفت که متغیر زمان دارای بیشترین تاثیر در تعیین بزرگای زلزله بوده است. بطور کلی بهترین پیش‌بینی مربوط به مدل N161 با روش آموزشی برخط بود.

نهایتاً، از آن جا که مدل پیشنهادی، مدلی است جامع و بدون هرگونه فرض اولیه، می‌توان از آن در مدل‌سازی‌های مشابه در زمینه پیش‌بینی بزرگای زلزله در موارد مطالعاتی دیگر استفاده نمود و انتظار می‌رود که نتایج حاصل برای مطالعات دیگر نیز به خوبی نتایج این پژوهش باشد.

## References

- [1] Vellido A, Lisboa P J G & Vaughan J (۱۹۹۹) Neural Networks in Business: A Survey of Applications-۱۹۹۲)  
(۱۹۹۸Expert Systems with Applications, ۱۷: ۵۱-۷۰).

## مراجع

همان‌گونه که از جدول (۴) پیداست، شبکه توانایی بسیار بالایی در پیش‌بینی بزرگای طبقه A و همچنین در بسیاری از موارد توانایی بالایی در پیش‌بینی بزرگای طبقه B داشته است، اما موفقیت شبکه در پیش‌بینی بزرگای مربوط به طبقه‌های C و D کمتر بوده‌است. علت این امر را می‌توان فراوانی زیاد داده‌های مربوط به طبقه‌های A و B و فراوانی کم داده‌های مربوط به طبقه‌های C و D دانست، چراکه وجود داده‌های زیاد در یک طبقه موجب می‌شود که شبکه عصبی فرصت کافی را برای یادگیری پیدا کند و پیش‌بینی‌های صحیح‌تری انجام دهد، اما در طبقه‌های با فراوانی کمتر این فرصت برای یادگیری فراهم نبوده و توانایی پیش‌بینی شبکه کاهش می‌یابد. این نکته قابل گفتن است که با وجود فراوانی بسیار کم طبقه‌های C و D (که شامل زلزله‌های بزرگ است)، شبکه توانسته است در مواردی موفق به کشف رابطه و یافتن شباهت بین داده‌ها شود و دست به پیش‌بینی صحیح بزند.

- [7] Kimura T, Ikeguchi T (۲۰۰۷) an optimum strategy for dynamic and stochastic packet routing problems by chaotic neurodynamics, *Integrated Computer-Aided Engineering*, ۱۴(۴): ۳۲۲-۳۰۷
- [8] Chih Fong T, Yen Jiun Ch (۲۰۰۹) Earnings Management Prediction: A Pilot Study of Combining Neural Networks and Decision Trees, *Journal of Expert Systems with Applications*, ۳۶: ۷۱۸۳-۷۱۹۱
- [9] SPSS Neural Networks ۱۷,۰ manual
- [10] International Institute of Earthquake Engineering and Seismology (IIEES) ground motion data base
- [11] Gardner, J. K., and L. Knopof (1974) Is the sequence of earthquakes in Southern California, with aftershocks removed, Poissonian?, *Bulletin of the Seismological Society of America*, 64(5): 1363-1367
- [12] Reasenber, P (1985) Second-order moment of central California seismicity, *Journal of Geophysical Research*, 90 : 5479-5495
- [13] Uhrhammer, R. (1986), Characteristics of Northern and Central California Seismicity, *Earthquake Notes*, 57(1): 21
- [14] Iranian Code of Practice for Seismic Resistant Design of Buildings (Standard No. ۲۸۰۰) ۳rd edition
- [2] Yau W C, Kumar D K, Arjunan S P (۲۰۰۷) Visual recognition of speech consonants using facial movement features, *Integrated Computer-Aided Engineering*, ۱۴(۱): ۶۱-۴۹
- [3] Cichocki A, Zdunek R (۲۰۰۷) Multilayer nonnegative matrix factorization using projected gradient approaches, *International Journal of Neural Systems*, ۱۷(۶): ۴۴۶-۴۳۱
- [4] Adeli H, Ghosh Dastidar, S, Dadmehr N (۲۰۰۸) a spatio-temporal wavelet-chaos methodology for EEG-based diagnosis of Alzheimer's disease, *Neuro- science Letters*, ۴۴۴(۲): ۱۹۴-۱۹۰
- [5] Senouci A B, Adeli, H. (۲۰۰۱) Resource scheduling using neural dynamics model of Adeli and Park, *Journal of Construction Engineering and Management*, ASCE, ۱۲۷(۱): ۳۴-۸
- [6] Cyganek B (۲۰۰۸) Color image segmentation with support vector machines: Applications to road signs detection, *International Journal of Neural Systems*, ۱۸(۴): ۳۳۹\_۳۴۵





# Prediction of Earthquake Magnitude Using Multilayer Perceptron Neural Network

M.A. Arjomand<sup>1</sup>, J. Mahmoudi<sup>2\*</sup>, M. Rezaei<sup>3</sup>, M.H. Mohammadi<sup>4</sup>

1. Assistant Professor, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

2- M.Sc. Student, Faculty of Civil Engineering, K.N.Toosi University of Technology, Tehran, Iran

3- M.Sc. Student, Faculty of Earthquake Engineering, Road-Building and Housing Research Center, Tehran, Iran

4- M.Sc. Student, Faculty of Civil Engineering, Kharazmi University, Tehran, Iran

jmahmoudi@mail.kntu.ac.ir

## Abstract:

Theoretical and empirical equations -developed for calculating the magnitude of earthquakes- are affected by several parameters. Most of these parameters need to be measured and entered in the equations accurately; while, lack of the required equipments in many areas, results in approximate measurement of these parameters or even consideration of assumed values. Moreover, most of the mentioned equations are presented exclusively for a specific region or state; therefore, they are not reliable enough for other regions. On the other hand, neural networks are proved to be one of the most practical numerical tools in modelling and forecasting. There are three major advantages of neural networks. First: their ability to learn any complex non-linear mapping; Second: their independency of a priori assumption about the distribution of data; Third: their flexibility with respect to incomplete, missing and noise data (Vellido et al, 1999). Moreover, neural networks, regardless of the region and country, are known as general solvers. Aim of this paper is to use Multilayer Perceptron (MLP), as one of the most influential neural network models, in predicting the magnitude of the earthquakes. This method consists of several layers of nodes. It includes an input layer, an output layer, and a hidden layer, each of which contains input node(s), output node(s), and hidden node(s), respectively. Characteristics of input nodes are defined with some variables, where in this research, three spatial variables, one time variable and two physical variables are adopted as six independent variables. The output nodes of neural networks are the prediction outputs or labels. The seismic data that is used in this research are gathered from the recorded earthquakes of Iran. 85% of the whole data is used for network training and 10% of that, for network testing and revising. The remained 5% is dedicated to derive the final prediction of the magnitudes of earthquakes. These predictions are then compared with exact values to assess the ability of the network. In the hidden layer, as there is no method to directly select the optimal number of hidden nodes, four different numbers of hidden nodes are chosen; including 8, 12, 16 and 20. As "overtraining" is the main problem with neural networks, a set of four different learning epochs are used, including 1, 2, 4 and 8. Moreover, in training part, two different training methods, named Batch and Online, are applicable. In order to reach more comprehensive results, both of these methods are applied and finally, 32 different groups of parameters and models are set up. According to the results, the average correct prediction of the models is about 70%. This means that the MLP network has a good capability for predicting the magnitude of earthquakes and can perform as a functional tool in predicting the magnitude of the earthquake regardless of the dependency to the time and location.

**Keywords:** Multilayer Perceptron, Neural Network, Earthquake Magnitude, Prediction, Training Method