

تخمین انرژی شکست بتن با استفاده از شبکه عصبی مصنوعی

حسن افشین^{*}، نقدعلی چوپانی^۲ و هادی فتحی پور آذر

^۱ دانشیار دانشکده مهندسی عمران، دانشگاه صنعتی سهند

^۲ دانشیار دانشکده مهندسی مکانیک، دانشگاه صنعتی سهند

^۳ دانشجوی کارشناسی ارشد مکانیک سنگ، دانشکده مهندسی معدن، دانشگاه صنعتی سهند

چکیده

بتن یکی از رایج‌ترین مصالح صنعتی و ساختمانی است که به دلیل اقتصادی بودن اهمیت روز افزونی پیدا می‌کند. در سال‌های اخیر با بهره‌گیری از روش‌های مختلف آزمایشگاهی، پارامترهای شکست مواد سیمانی مانند بتن مورد بررسی قرار گرفته است؛ نقش این پارامترها در طراحی سازه‌های سطحی و زیرسطحی از اهمیت ویژه‌ای برخوردار است. در این مقاله مدل شکست بر اساس شبکه عصبی برای تخمین پارامتر شکست بتن G_F (انرژی مخصوص شکست) که مساحت زیر منحنی تنش- بازدگی نوک ترک است) در بارگذاری تحت خمش سه نقطه‌ای (3PB) ارائه شده است. می‌توان با استفاده از شبکه عصبی و آموزش صحیح شبکه و متعاقباً ایجاد رابطه منطقی بین متغیرهای ورودی و خروجی، مدل بهینه‌ای برای هر سری از داده‌ها ایجاد کرد و سپس با ارزیابی دقیق شبکه، از آن‌ها به عنوان یک ابزار مؤثر برای تخمین انرژی شکست بتن استفاده کرد.

واژگان کلیدی: شبکه عصبی مصنوعی، مکانیک شکست، بتن، تخمین، انرژی شکست.

اقدام مؤثری انجام نشده بود [۳] در سال Kaplan. ۱۹۶۱ مطالعاتی را برای تعیین پارامترهای شکست بتن شروع کرد. ایشان از اصل مکانیک شکست الاستیک خطی کلاسیک (LEFM)^۱ برای تعیین پارامترهای منحصر بفرد (ضریب شدت تنش بحرانی و یا انرژی کرنشی بحرانی) شکست بتن استفاده کرد [۳] و [۴]. Kesler و همکارانش در ۱۹۷۱ نتیجه گرفتند که مکانیک شکست الاستیک خطی با تنها یک پارامتر شکست یعنی انرژی شکست G_f (یا چقرمگی شکست K_C) برای بتن غیر قابل کاربرد بوده و حداقل دو پارامتر لازم می‌باشد. در ۱۹۷۶ با استفاده از مطالعات مدل‌های اجزای محدود گسترش ترک و آزمایش‌های شکست و تشخیص مدل توسعه نواری ترک مشخص شد که ویژگی‌های شکست به وسیله میانگین شیب کرنش نرم شونده بعد از ماکریم مقدار به مشخصه‌های خاص ناحیه نواری جلوی ترک مربوط می‌شود (که با همدیگر دلالت بر مقدار انرژی شکست G_f دارند). گام بزرگ و عمده به وسیله Hillerborg و همکارانش برداشته شد که مدل ترک مجازی را برای بتن معرفی کردند بطوری که در شیب اولیه منحنی تنش نرمی- بازدگی یا مساحت زیر منحنی با پارامتر مقاومت کششی دلالت به دو پارامتر شکست اساسی مواد دارد. این دو پارامتر سپس در

۱- مقدمه

در سال ۱۹۶۱ Kaplan مطالعاتی را در مورد کاربرد مکانیک شکست برای بتن انجام داد [۱]. در چند دهه اخیر روش‌های مدل‌سازی مختلف براساس هوش مصنوعی و سیستم‌های منعطف به وسیله بسیاری از محققان برای بتن برای کاربردهای مهندسی مختلف از جمله عمران، معدن و تونل‌سازی استفاده شده است. در این روش‌ها آموزش بر مبنای خصوصیات رفتاری مصالح و نتایج بدست آمده از آزمایش می‌باشد. بعد از آموزش، شبکه اطلاعات کافی از خصوصیات مدل را دارا می‌باشد. این شبکه نه تنها قادر است بر اساس داده‌های موجود آزمایش، جواب قابل قبولی بدهد بلکه می‌تواند برای موارد مشابه نیز مورد استفاده قرار گیرد [۲]. هدف از این مطالعه ساختن مدل شبکه عصبی مصنوعی (ANN)^۲ جهت تخمین انرژی شکست بر اساس پارامترهای ورودی شامل سن بتن، نسبت مقاومت فشاری به کششی، مدول الاستیسیته، نسبت آب به سیمان، نوع سنگدانه، اندازه بزرگترین سنگ‌دانه (d_{max}) می‌باشد.

۲- مکانیک شکست بتن

بعد از مطالعات Griffith در مورد مکانیک شکست در سال ۱۹۲۱ تا مدت نیم قرن برای کاربرد این نوع مکانیک در بتن

در مورد وابستگی انرژی شکست به اندازه، بعضی محققان با انجام آزمایش‌ها آن را مستقل و تفاوت نتایج را در خطاهای نصب آزمایشگاهی و عواملی از این قبیل دانسته‌اند. لازم به ذکر است که اکثر این آزمایش‌ها، آزمایش خمش سه نقطه‌ای بوده است [۸]. برای تحلیل ساختار بتن طبق مکانیک شکست ابتدا لازم است پارامترهای شکست تعیین شود [۴].

۱-۲- مدل ترک مجازی هیلربورگ

Hillerborg اولین بار مدل ترک مجازی (FCM)^۵ را برای بتن ارائه کرده است و G_F از روش پیشنهادی کار-شکست (WFM) وی (پیشنهادی RILEM 50FCM) و با استفاده از رابطه زیر بدست می‌آید:

$$G_F = \frac{1}{B(W-a)} \int P d\delta \quad (1)$$

که a طول شکاف یا ترک اولیه در تیر خمش سه نقطه‌ای (3PB)، W عرض نمونه و B ضخامت نمونه می‌باشد. $\int P d\delta$ کل انرژی شکست و $B(W-a)$ کل سطح زیر منحنی نیرو-تفییر مکان نقطه بارگذاری است. با تحلیل رابطه بالا به رابطه زیر می‌رسیم:

$$G_F = \int_0^{W_c} \sigma(w) dw \quad (2)$$

که W_c میزان بازشدنی بحرانی ترک است [۴ و ۶ و ۹]. انرژی شکست به عنوان میزان انرژی مورد نیاز برای ایجاد ترک در واحد سطح در صفحه‌ای به صورت موازی با جهت ترک تعریف می‌شود [۱۰].

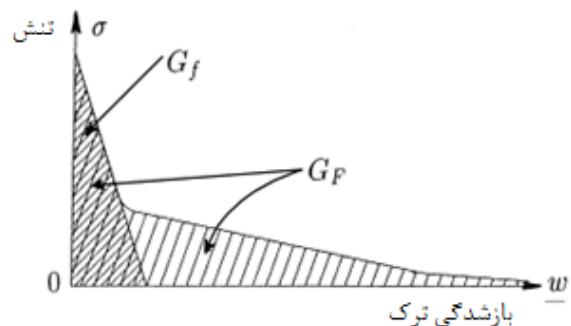
۳- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (ANN) از سیستم‌های عصبی زیستی (مغز انسان) الگو برداری کرده است که اطلاعات را پردازش می‌کند اما در مقایسه با مغز انسان نسبتاً ساده و کارکرد آسانی دارد. اولین مطالعات مربوط به شبکه عصبی به ۱۹۴۳ برمنی گردد [۲ و ۱۰-۱۲]. در سال‌های اخیر شبکه عصبی مصنوعی در بسیاری از مسائل مهندسی عمران و تونل سازی مانند پیش‌بینی خرابی سازه‌ها، مدل

مدل ترک الاستیک مؤثر (ECM) و Nallathambi (TPM) Shah و Jenq استفاده شده است [۳]. مدل ترک مجازی هیلربورگ به وسیله Dugdale و Barenblatt شکست بتن توسعه یافته است [۵]. انرژی شکست بطور معمول به G_F که با G_f تفاوت دارد، وابسته است. G_F بصورت ناحیه كامل زیر منحنی بار-تفییر شکل اندازه‌گیری می‌شود که به نواحی مربوطه تقسیم‌بندی شده است. مقدار G_F به وسیله روش کار-شکست (WFM)^۶ که کاملاً حساس به اندازه نمونه و شکل آن است بدست می‌آید و از طرف دیگر انرژی شکست G_f به وسیله روش اثر اندازه (SEM)^۷ تعیین می‌شود [۳]. مساحت کامل زیر منحنی تنش نرم شونده-بازشدنی برابر با G_F و مساحت زیر منحنی تا تنش ماکریم نیز برابر با G_f می‌باشد (شکل ۱). دانشمندانی همچون پلنیز، ایلسیس و بازانت و بیک-گرای-دون مقدار G_F/G_f را برابر

۲-۵/۲ تخمین زند [۳ و ۶].

بهترین راه برای تعیین انرژی شکست استفاده از تنش یک محوره مستقیم می‌باشد. ولی از آن جائی که انجام روش کشش مستقیم برای این گونه مواد آسان نیست، اکثراً از آزمایش سه نقطه‌ای (3PB) پیشنهاد شده به وسیله RILEM TC50-FMC استفاده می‌شود [۷]. در این تحقیق نیز از داده‌های مربوط به این نوع آزمایش استفاده شده است. انرژی شکست پارامتر اساسی شکست است که معرف مقاومت ترک در برابر گسترش ترک خوردنی و مانند چقمه‌گی شکست بتن، در مکانیک شکست و تحلیل ترک‌ها از خصوصیات ماده محسوب می‌شود.



شکل ۱- منحنی تنش بازشدنی نوک ترک در مدل ترک مجازی، مساحت زیر منحنی معرف G_F (انرژی شکست کل) و G_f (انرژی شکست تا بار بحرانی) [۳].

- 1- Effective crack model
- 2- Two-parameter model
- 3- Work-of-fracture method
- 4- Size effect model

ب) تعداد دوره‌های آموزش
پ) تعداد پارامترهای ورودی شبکه
دلیل بررسی این پارامترها این است که افزایش تعداد دوره‌ها باعث بیش‌یادگیری می‌شود بدین معنی که این بیش‌یادگیری در مورد داده‌های آموزش منجر به دقت بالا ولی در مورد داده‌های ارزیابی منجر به ایجاد خطای زیاد می‌گردد و تعداد نمونه‌های کم باعث دقت کم به ازای ورودی‌ها جهت تولید نتیجه می‌شود و نیز تعداد نمونه‌های زیاد باعث بیش‌یادگیری و خطای برای داده‌های ورودی جدید می‌شود. همچنین برای کارایی مدل بر اساس داده‌های آموزش و اعتبارسنجی و ارزیابی از میانگین مربعات خطای استفاده شده است که رابطه آن به صورت زیر است:

$$MSE = \frac{1}{PC} \sum_i^P \sum_k^C (t_{ik} - o_{ik})^2 \quad (3)$$

در این رابطه، C و P به ترتیب تعداد سلول در خروجی و تعداد الگو، و t و o هدف و خروجی مدل i امین سلول خروجی-زمین الگو می‌باشند.

۳-۲- ورودی‌ها و خروجی‌های شبکه عصبی

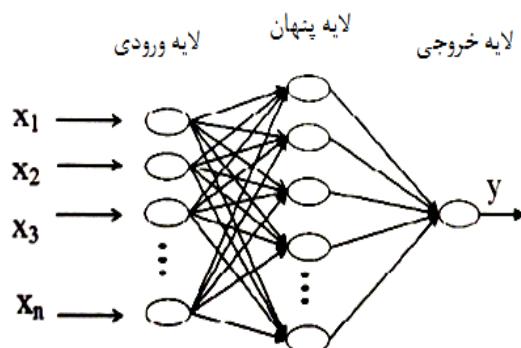
نتایج آزمایشگاهی نشان می‌دهند که پارامترهای شکست بتن به طور ویژه‌ای متاثر از نوع سنگ دانه، بیشترین اندازه سنگ دانه (d_{max})، مقاومت فشاری (f'_c) و نسبت آب به سیمان (W/C) است. همچنین مکانیک شکست می‌تواند متاثر از سایر پارامترهای مواد مانند نوع سیمان، نسبت کل سنگ دانه به ماسه و شرایط عمل آوری بتن و غیره باشد [۱۲]. به همین خاطر شبکه بر اساس پارامترهای ورودی، سن بتن، نوع سنگ دانه، بیشترین اندازه سنگ دانه (d_{max} ، نسبت مقاومت فشاری به کششی (f'_c/f'_t)، نسبت آب به سیمان (W/C) و مدول الاستیسیته و یک پارامتر خروجی انرژی شکست G_F آموزش دیده است.

از آن جایی که محدوده داده‌ها متفاوت می‌باشد بنابراین داده‌ها (هم ورودی و هم خروجی) بین $0/1$ تا $0/9$ با استفاده از رابطه زیر نرمالیزه شده‌اند:

$$x_i^n = 0.1 + \frac{x_i^a - x_i^{\min}}{x_i^{\max} - x_i^{\min}} 0.8 \quad (4)$$

کردن رفتار مصالح، بهینه‌سازی ساختارها، کنترل ساختارها، نظارت بر آب زیرزمینی، پیش‌بینی نشت در فونداسیون‌های کم عمق و پیش‌بینی در نتایج آزمایشگاهی و نسبت‌های اختلاط بتن و ملات بکار رفته است [۲ و ۱۰].

شبکه عصبی از ۵ قسمت تشکیل شده است: ورودی، وزن‌ها، بایاس^۱، تابع عملکرد و خروجی. ورودی‌ها، اطلاعات ورودی به شبکه، وزن‌ها میزان تأثیر ورودی بر روی خروجی و بایاس میزان تأثیر ورودی مقدار ثابت ۱ روی نمونه می‌باشد. وزن‌ها و بایاس قابل تنظیم بوده و تابع عملکرد نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب تابع عملکرد و نوع الگوریتم یادگیری پارامترهای وزن و بایاس تنظیم می‌شوند و یادگیری بدین معنی است که با تغییر وزن و بایاس رابطه منطقی بین ورودی‌ها و خروجی پیدا شود [۱۱]. حداقل تعداد لایه‌ها ۳ عدد است: لایه ورودی، لایه پنهان و لایه خروجی (شکل ۲). تعداد لایه‌های اضافی به دقت و نتیجه داده‌های خروجی بستگی دارد و تعداد نمونه در لایه ورودی وابسته به تعداد ورودی‌ها می‌باشد و تعداد نمونه لایه میانی به تشخیص و مهارت طراح شبکه بستگی دارد.

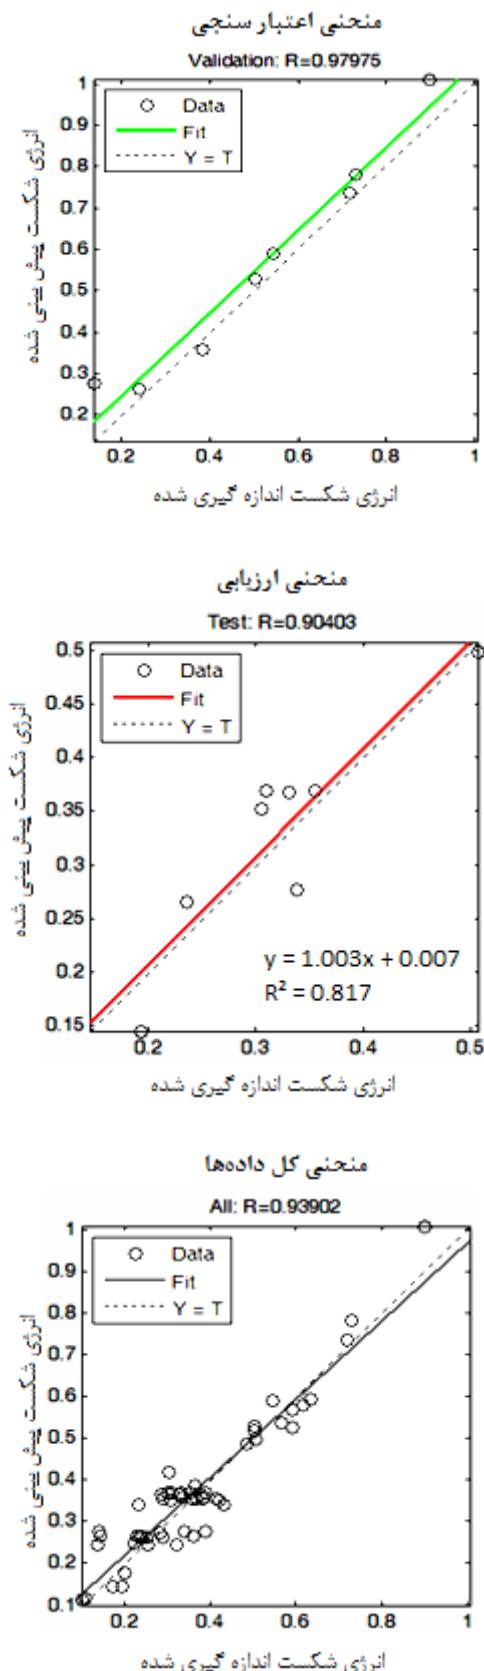


شکل ۲- ساختار شبکه عصبی

۳-۱- مدل شبکه عصبی برای انرژی شکست G_F

از ۵۵ داده، ۳۹ مورد برای آموزش، ۸ مورد برای اعتبار سنجی و ۸ مورد برای ارزیابی داده استفاده شده است که ۶ نمونه در لایه پنهان و یک نمونه در لایه خروجی می‌باشد. در این مطالعه از داده‌های مرجع [۳] که در پیوست (الف) آمده، استفاده شده است.

پارامترهای مختلفی براساس سعی و خطای مورد ارزیابی قرار گرفته‌اند که عبارتند از:
 الف) معماری کلی ساختار شبکه: تعداد لایه‌های مخفی و همچنین تعداد نمونه‌ها در این لایه‌ها



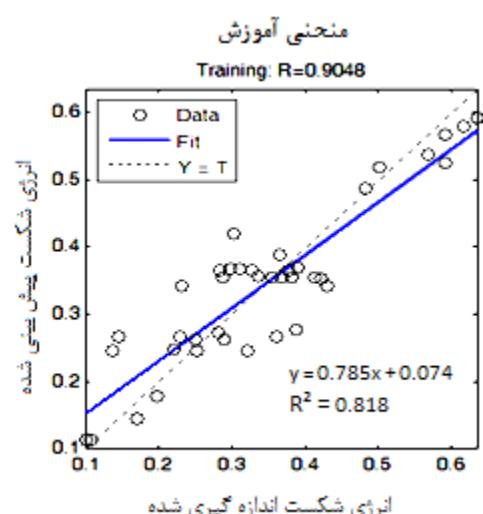
شکل ۳- برآورد خطی مدل شبکه عصبی آموزش، اعتبارسنجی، ارزیابی و کل داده‌ها

که در این رابطه x_i^a و x_i^n داده ورودی و خروجی نرمالیزه شده و x_i^{\min} و x_i^{\max} کوچکترین و بزرگترین داده در آن نوع ورودی می‌باشد.

۴- تخمین انرژی شکست بتن به وسیله شبکه عصبی

در این مطالعه، شبکه عصبی پرسپترون چند لایه (MLP)^۱ پیش رو با الگوریتم پس انتشار خطای استفاده شده است. شبکه پیش رو مشکل از نرون‌ها است که خروجی هر لایه از نرون‌ها ورودی لایه بعدی می‌باشد [۱۰]. الگوریتم پس انتشار خطای یکی از شناخته شده‌ترین الگوریتم‌های آموزشی برای پرسپترون چند لایه است که از الگوریتم‌های آموزش خاص با انتقال خطای از لایه انتهایی به لایه قبلی انجام می‌شود که در کمترین زمان وزن‌ها و باسیاس را تنظیم می‌کند. برای آموزش شبکه از روش لونبرگ- مارکوات (LM)^۲ استفاده شده است. این شبکه با لایه پنهان سیگموئید با تعداد نرون برابر ۶ و لایه خروجی خطی برای آموزش استفاده شده است. از نرم‌افزار MATLAB برای مدل‌سازی استفاده شده است.

مدلی با کمترین خطای (جداول (۱) و (۲)) برای پیش‌بینی انرژی شکست با توجه به شکل (۳) و سه مرحله آموزش و اعتبارسنجی و ارزیابی بدست آمد. که با توجه به جدول (۱)، مقادیر تابع عملکرد و ضریب همبستگی نتایج بسیار خوبی با کمترین خطای را نشان می‌دهند.



جدول ۱- نتایج آموزش شبکه

R	RMSE	MSE	
۰/۹۰۴۸	۰/۰۵۸۳	۰/۰۰۳۴	داده‌های آموزش
۰/۹۷۹۷	۰/۰۶۸۶	۰/۰۰۴۷	داده‌های اعتبار سنجی
۰/۹۰۴۰	۰/۰۴۲۴	۰/۰۰۱۸	داده‌های ارزیابی

R: ضریب همبستگی، (Mean Square Error) :MSE ، میانگین مربعات خطأ

RMSE: ریشه میانگین مربعات خطأ

جدول ۲- مقایسه نتایج ارزیابی شبکه با مقادیر واقعی انرژی شکست با استفاده از تکنیک لونبرگ- مارکوات

مقادیر واقعی	۱۰۵	۶۰	۷۱/۶	۷۶/۹	۷۵/۷	۷۹/۷	۷۲/۳	۵۳
خروجی شبکه	۱۰۳/۵۷	۶۵/۰۶	۷۹/۲۳	۶۶/۷۶	۸۱/۸۵	۸۲/۰۱	۸۲/۰۱	۴۵/۱۶
خطای نسبی٪	۱/۳۶	۸/۴۳	۱۰/۶۶	۱۲/۱۸	۸/۱۲	۲/۹	۱۳/۴۳	۱۴/۷۹

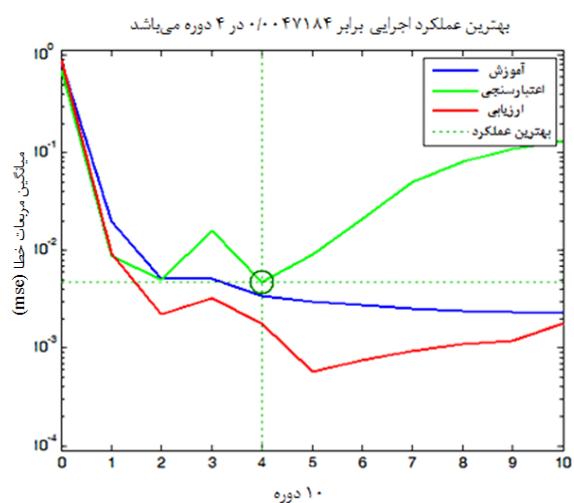
۵- نتیجه‌گیری

- ۱- با توجه به اینکه تهیه و آماده‌سازی نمونه جهت انجام آزمایش هزینه‌بر، زمان‌بر، و نیازمند دقت بالایی است با توجه به نتایج ضریب همبستگی $R=0.90$ ، میانگین مربعات خطأ $MSE=0.0018$ و $RSME=0.042$ برای داده‌های ارزیابی، شبکه عصبی مصنوعی (شبکه عصبی چندلایه پیشرو (MLP)) می‌تواند با سطح اطمینان قابل قبولی برای تخمین پارامترهای شکست بتن بکار رود.
- ۲- با توجه به این که یافتن روابط مکانیک شکست به روش‌های عددی، تجربی و تحلیلی چهت یافتن پارامترهای شکست و آن گاه تحلیل رشد ترک مهم می‌باشد، شبکه عصبی کارایی بالایی چهت تخمین پارامترهای مذکور دارد.
- ۳- با توجه به اینکه با افزایش داده‌های تأثیرگذار، جواب دقیق‌تر می‌شود (خطای نسبی کاهش می‌یابد) و از طرفی پارامترهای دخیل در مکانیک شکست بتن زیاد می‌باشند، لذا پیدا کردن یک رابطه منطقی و ریاضی مشکل می‌باشد ولی نتایج این تحقیق نشان می‌دهند که ابزاری مثل شبکه عصبی مصنوعی به دلیل غیر خطی بودن، انعطاف‌پذیری زیاد، خطای کم و همچنین قابلیت حذف و اضافه نمودن هر تعداد از عوامل دیگر، قابلیت‌های بسیار بیشتری نسبت به روابط تجربی دارد و در این مورد مناسب است.

۶- مراجع

- [1] Kaplan, M., "Crack Propagation and the Fracture of Concrete", American Concrete Institute ACI. J., 1961, 58 (5), 591-610.

داده‌های آموزش شبکه می‌باشند و داده‌های اعتبارسنجی تأثیری در روند آموزش ندارند و داده‌های اعتبارسنجی اکثراً چهت اعتبارسنجی و انتخاب تعداد دوره آموزش مناسب بکار می‌روند. همانطوری که در شکل (۴) ارائه شده است، در موردی که شبکه عصبی مصنوعی با داده‌های آموزش، آموزش داده می‌شود، با افزایش تعداد دوره، خطای داده‌های آموزش کاهش می‌یابد. اگر در منحنی زیر روند تغییرات خطأ و اعتبارسنجی را در نظر بگیریم ملاحظه می‌شود که تا تعداد دوره ۴، خطای اعتبارسنجی کاهش یافته و بعد از آن رو به افزایش است این لحظه حالتی است که می‌گوئیم شبکه در حال تخصصی شدن است و در این نقطه آموزش را باید متوقف کرد و همان تعداد دوره را در نظر گرفت که با توجه به کار انجام شده و نمودار زیر تعداد دوره مناسب ۴ و با بهترین عملکرد اجرایی ۰/۰۰۴۷ می‌باشد.



شکل ۴- تغییرات MSE در مقابل دوره

- Softening Curve of Concrete: Part I. Experiments and Fracture Energy", Cement and Concrete Research, 2008, 38 (8-9), 1049-1060.
- [9] Hu, X., Duan, K., "Influence of Fracture Process Zone Height on Fracture Energy of Concrete", Cement and Concrete Research, 2004, 34 (8), 1321-1330.
- [10] Topcu, I. B., Karakurt, C., Saridemir, M., "Predicting the Strength Development of Cements Produced with Different Pozzolans by Neural Network and Fuzzy Logic", Materials & Design, 2008, 29 (10), 1986-1991.
- [11] منهاج، م.. "هوش محاسباتی (جلد اول): مبانی شبکه‌های عصبی"، مرکز نشر دانشگاه صنعتی امیرکبیر، چاپ ششم، تهران، ۱۳۸۸.
- [12] INCE, R., "Artificial Neural Network Based Analysis of Effective Crack Model in Concrete Fracture", Fatigue & Fracture of Engineering Materials & Structures, 2010, 33 (9), 595-606.
- [2] Topcu, I. B., Saridemir, M., "Prediction of Compressive Strength of Concrete Containing Fly Ash Using Artificial Neural Networks and Fuzzy Logic", Computational Materials Science, 2008, 41(3), 305-311.
- [3] Bazant, Z. P., Becq-Giraudon, E., "Statistical Prediction of Fracture Parameters of Concrete and Implications for Choice of Testing Standard", Cement and Concrete Research, 2002, 32 (4), 529-556.
- [4] Ince, R., "Prediction of Fracture Parameters of Concrete by Artificial Neural Networks", Engineering Fracture Mechanics, 2004, 71 (15), 2143-2159.
- [5] Roesler, J., Paulino, G. H., Park, K., Gaedicke, C., "Concrete Fracture Prediction Using Bilinear Softening", Cement and Concrete Composites, 2007, 29 (4), 300-312.
- [6] Einsfeld, R. A., Velasco, M. S. L., "Fracture Parameters for High-Performance Concrete", Cement and Concrete Research, 2006, 36(3), 576-583.
- [7] Reis, J., Ferreira, A., "A contribution to the Study of the Fracture Energy of Polymer Concrete and Fiber Reinforced Polymer Concrete", Polymer Testing, 2004, 23 (4), 437-440.
- [8] Zhao, Z., Kwon, S. H., Sandra, S. P., "Effect of Specimen Size on Fracture Energy and

بیوست الف- داده‌های استفاده شده در شبکه عصبی مصنوعی [۳]

بتون	مقاومت فشاری (MPa)	مقاومت کششی (MPa)	مدول الاستیسیته (GPa)	نسبت آب به سن سیمان w/c	نوع سنگدانه	قطر سنگدانه (mm)	انرژی شکست (N/m)
۲۸	۳۱	۲/۷	۳۲/۳	۰/۵۴	RhR ^۱	۳۲	۱۴۲
۴۰	۳۱	۲/۷	۳۲/۳	۰/۵۴	RhR	۳۲	۱۷۰
۲۸	۳۵	۳	۲۵/۷	۰/۵۴	RhR	۲	۵۳
۲۸	۳۵	۳	۲۵/۷	۰/۵۴	RhR	۲	۴۹/۳
۴۰	۳۵	۳	۲۵/۷	۰/۵۴	RhR	۲	۳۷/۶
۲۸	۹۳	۳/۸	۳۲	۰/۴	CA ^۲	۸	۱۴۰
۲۸	۲۸	۲/۴	۳۱	۰/۸	CA	۸	۱۱۹
۲۸	۶۸	۳/۶	۳۹	۰/۴	NA ^۳	۱۲	۱۲۶
۲۸	۲۱	۲/۳۳	۲۶	۰/۸	NA	۱۲	۷۱
۲۷	۲۹	۳/۱	۲۱/۷	۰/۶	GRA ^۴	۱۰	۷۲/۳
۲۷	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۷۹/۷
۲۷	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۸۵/۶
۲۸	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۷۰/۵
۲۸	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۷۵/۷
۲۸	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۷۲/۴
۲۹	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۸۳/۴
۲۹	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۷۵/۳
۲۹	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۶۸/۱
۳۲	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۶۸/۶
۳۲	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۸۴/۱
۳۲	۲۹	۳/۱	۲۱/۷	۰/۶	GRA	۱۰	۷۹/۸
۲۸	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۸۰/۸
۲۹	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۸۵/۳
۳۲	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۶۹
۳۲	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۷۴/۲
۲۸	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۵۸/۹
۲۹	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۷۶/۹
۳۲	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۶۰/۸
۳۲	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۶۲/۷
۲۸	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۴۴/۹
۲۹	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۴۳/۸
۳۲	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۶۲/۵
۳۲	۵۸/۹	۴/۲	۲۴/۵	۰/۴	GRA	۱۰	۴۳/۶
۲۸	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۷۶/۶
۲۹	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۸۱/۹
۳۰	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۷۱/۶
۳۲	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۵۹/۲
۲۸	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۸۴/۷
۲۹	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۸۹/۵

پیوست الف - ادامه

بن	مقاومت فشاری (MPa)	مقاومت کششی (MPa)	مدول الاستیسیته (GPa)	نسبت آب به سن سیمان w/c	نوع سنگدانه	قطر سنگدانه (mm)	انرژی شکست (N/m)
۳۰	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۹۰/۷
۳۲	۳۳/۱	۳/۵	۱۹/۷	۰/۵۵	GRA	۱۰	۹۲/۲
۲۸	۵۲/۶	۳/۸	۴۱/۹	۰/۵	CQ ^۵	۱۲	۱۰۴
۲۸	۴۲/۹	۳/۴۵	۴۱/۳	۰/۵	GRA	۱۲	۱۰۴
۲۸	۵۹/۸	۴/۵۵	۳۰	۰/۵	CL ^۶	۱۲	۶۰
۲۸	۱۹/۸	۲/۲	۱۸/۱	۰/۵	EC ^۷	۱۲	۳۸/۸
۲۸	۸۵/۹	۴/۵	۴۸/۱	۰/۳	CQ	۱۲	۱۱۵
۲۸	۷۴	۴/۳	۴۴/۴	۰/۴	CQ	۱۲	۱۱۹
۲۸	۲۹/۸	۲/۴۵	۳۶/۳	۰/۷	CQ	۱۲	۸۱/۳
۲۸	۵۵/۹	۳/۸	۴۳/۸	۰/۵	CQ	۱۲	۱۲۳
۲۸	۵۴/۴	۳/۸	۴۱/۳	۰/۵	CQ	۱۲	۱۰۵
۲۸	۵۲/۷	۴	۴۳/۱	۰/۵	CQ	۸	۱۰۱
۲۸	۵۵/۳	۳/۴	۴۱/۹	۰/۵	CQ	۱۶	۱۱۱
۲	۲۶/۱	۱/۸۵	۳۱/۳	۰/۵	CQ	۱۲	۸۲/۵
۷	۴۲/۴	۳	۳۸/۸	۰/۵	CQ	۱۲	۹۶/۳
۹۱	۶۳	۴/۲۵	۴۴/۴	۰/۵	CQ	۱۲	۱۱۴

1- Rhine river sand and gravel,

2- Crushed aggregate,

3- Natural aggregate,

4- Gravel,

5- Crushed quartzite,

6- Crushed limestone,

7- Expanded clay

Estimating Fracture Eenergy of Concrete Using Artificial Neural Networks

H. Afshin ¹, N. Choupani ² and H. Fathipour Azar ³

¹ Faculty of Civil Engineering, Sahand University of Technology

² Faculty of Mechanical Engineering, Sahand University of Technology

³ Faculty of Mining Engineering, Sahand University of Technology

Abstract

Concrete is one of the most common industrial and constructional materials due to its economical aspects. In recent years, fracture parameters of cement-based materials, such as concrete have been studied using the development of mathematical models derived from various experimental data and methods. The role of these parameters in design of structures is an important issue. In this paper, a fracture model based on artificial neural network, as an alternative way and soft computing to reduce time and calculation content, has been applied to estimate the fracture parameters of concrete (specific fracture energy i.e. the area under the complete stress-strain curve) by loading under a three-point bending (3PB) specimen. Fracture parameters of concrete, model's output parameter, is predicted by input parameters: test age, aggregate type, maximum aggregate size (d_{max}), compressive-tensile strengths ratio (f'_c/f'_t), water-cement ratio (w/c), young's modulus (E). Because of the fewness of data, thirty nine data were used as training data and eight data were used as validation or testing data. By using the neural network and its proper training to create logical relationship between input and output variables, an optimal model for each series of data could be made, which can be applied to evaluate the network reliability as an effective tool to estimate the fracture energy of concrete. The results showed that the mathematical models can be used to estimate the fracture parameters of cement-based materials and concrete. Also it was shown that the feed-forward multi-layer perception back-propagation artificial neural network with Lovenberg-Marquardt training algorithm and with 2 layers which has 6 and 1 neurons in the first and second layer respectively with $R=0.90$ and $RMSE=0.04$ is most appropriate neural network for the estimation of fracture energy of concrete.

Keywords: Artificial neural networks (ANNs), Fracture mechanics, Concrete.

Received: June 2011

Accepted: December 2011