

به کارگیری شبکه عصبی مصنوعی در تحلیل داده‌های فرسایش‌پذیری رسوبات ریزدانه در محیط‌های دریاچی

ابراهیم حمیدیان جهرمی^۱، فرهنگ احمدی گیوی^۲، سید عباس حق‌شناس^۳

^۱دانشجوی کارشناسی ارشد، مؤسسه ژئوفیزیک دانشگاه تهران، eb_hamidian@ut.ac.ir

^۲دانشیار گروه آموزشی فیزیک فضا، مؤسسه ژئوفیزیک دانشگاه تهران، ahmadig@ut.ac.ir

^۳استادیار گروه آموزشی فیزیک فضا، مؤسسه ژئوفیزیک دانشگاه تهران، sahaghshenas@ut.ac.ir

چکیده

فرسایش یکی از فرآیندهای مهم در نواحی ساحلی و خورها محسوب می‌شود. آنچه فرسایش در رسوبات ریزدانه چسبنده را به یک پدیده پیچیده تبدیل می‌کند، طیف وسیع پارامترهای مؤثر بر آن است. از این‌رو یافتن یک الگوی واحد برای تنش برشی بحرانی (فرسایش) که اغلب از روند مشخصی برخوردار نیست، می‌تواند بسیار حائز اهمیت باشد. به عبارت دیگر، در دسترس نبودن یک ارتباط جامع و فراگیر میان فرسایش و پارامترهای گوناگون مؤثر و همچنین بررسی نشدن تأثیر تأم پارامترهای مختلف در یافتن یک الگوی واحد برای فرسایش در اکثر مطالعه‌های موجود را می‌توان از دلایل اهمیت موضوع این تحقیق به شمار آورد. در این مطالعه با استفاده از شبکه عصبی مصنوعی به واکاوی تأثیر تأم طیف پارامترهای فیزیکی، شیمیایی و زیست‌شناسی مختلف بر تنش برشی بحرانی و یافتن یک الگوی فرانمونه‌ای و نسبتاً جامع پرداخته شده است. بدین منظور، ابتدا ارزیابی عملکرد شبکه عصبی بر روی یک مجموعه داده انجام شد و در ادامه برای اطمینان از اتفاقی نبودن نتایج حاصل، به بررسی این روش بر روی یک مجموعه داده با ماهیت رسوبی متفاوت اقدام شده است. بنابر نتایج حاصل، امکان ارائه رابطه‌ای منطقی بین پارامترهای فیزیکی و شیمیایی رسوبات ریزدانه چسبنده و خصوصیات فرسایش‌پذیری این رسوبات در قالب شبکه‌های عصبی مصنوعی فراهم و ارائه شده است.

واژه‌های کلیدی: فرسایش، رسوبات ریزدانه چسبنده، تنش برشی بحرانی، یادگیری ماشینی، شبکه عصبی مصنوعی

Erodibility data analysis in coastal environments by applying Artificial Neural Networks

Ebrahim Hamidian J.¹, Farhang Ahmadi-Givi², S. Abbas Haghshenas³

¹ Graduate student, Institute of Geophysics, University of Tehran, eb_hamidian@ut.ac.ir

² Associate Professor, Institute of Geophysics, University of Tehran, ahmadig@ut.ac.ir

³ Assistant Professor, Institute of Geophysics, University of Tehran, sahaghshenas@ut.ac.ir

Abstract

Sediment erosion is one of the most important processes in coastal zones. What makes erosion in cohesive sediment a complicated process is vast numbers of parameters affecting erodibility. Accordingly, finding a unique pattern for critical shear stress is of considerable importance. As there is no or few studies available in the erosion literature presenting a comprehensive relation among erosion and involving parameters and not exploring the impacts of many physical and chemical parameters in tandem to find a unique erosion pattern, are just some of the utmost importance of doing this research. In this study, it is attempted to investigate the effect of various physical, chemical, mechanical and biological parameters on critical shear stress to find a thorough pattern in erosion. Hence, the efficiency of using Artificial Neural Network (ANN) on totally two different datasets (Kimiaghalam *et al.*, (2015) and Jacobs *et al.*, (2010)) has been investigated

Keywords: Erosion, cohesive sediments, critical shear stress, machine learning, artificial neural network.

۱ مقدمه

فرسایش یکی از فرآیندهای مهم در نواحی ساحلی و خورها محسوب می‌شود که می‌تواند تغییرات چشم‌گیر زمین‌ریخت‌شناسی و مشکلات زیست‌محیطی متعددی را در پی داشته باشد. از طرفی، فرسایش پدیده‌ای است که می‌تواند در زمان و مکان بسیار متغیر باشد. این موضوع خود بر دخیل بودن طیف وسیع پارامترهای مؤثر در فرسایش، دلالت دارد که در

برخی موارد یا شناخت دقیقی از نحوه تأثیرشان بر فرایش در دست نیست و یا نمی‌توان عملکرد آنها را به صورت کمی تعیین و در روابط گنجاند. بنابراین برای بررسی فرایش در هر منطقه، نیاز به مطالعه جداگانه اثر پارامترهای مختلف فیزیکی، شیمیایی و زیست‌شناختی است؛ اما آنچه ما را به سمت شناخت و درک جامع‌تر از این پدیده پیش می‌برد، در نظر گرفتن اثر تمامی این پارامترها به صورت همزمان و توأم است. از سوی دیگر، با استفاده از اغلب روش‌های آماری مرسوم همچون رگرسیون‌ها، نمی‌توان به‌آسانی به بررسی رابطه همزمان بیش از سه متغیر پرداخت. لذا، استفاده از روش‌های هوشمند مانند یادگیری ماشینی، انتخاب مناسبی بدین منظور به نظر می‌رسد. آنچه استفاده از روش‌های یادگیری ماشینی را برای بررسی چنین پدیده‌های پیچیده متمایز می‌کند، قابلیت ایجاد ارتباط بین پارامترهای دخیل در مسائلی است که یا تعداد پارامترها در آن بسیار زیاد است و یا تغییرات پارامترهای مورد بررسی در آنها، دارای روند روشی نیست. در بررسی پدیده‌هایی مانند فرایش، اغلب پارامترهایی وجود دارد که اندازه‌گیری میدانی متعدد آنها یا به‌آسانی می‌توانند بروزهایی مانند هزینه‌های گزافی را به پروژه تحمیل می‌کند. از این رو، در بسیاری موارد ترجیح بر استفاده از روش‌های غیرمستقیم برآورد این پارامترها است. به عنوان نمونه‌ای از این روش‌ها، می‌توان به یکی از روش‌های یادگیری ماشینی همچون شبکه عصبی مصنوعی اشاره کرد. طی دهه‌های اخیر مطالعات گوناگون و گسترده‌ای بر روی جنبه‌های مختلف رسوبات ریزدانه چسبنده از جمله فرایش صورت گرفته است. در این راستا، محققین بسیاری سعی بر یافتن رابطه میان پارامترهای فیزیکی، مکانیکی و الکتروشیمیایی با تنش برشی بحرانی داشتند. به عنوان یکی از اولین روابط برای رسوبات چسبنده، می‌توان به کارهای دان (۱۹۵۹) و اسرمدون و بیسلی (۱۹۶۱) اشاره کرد که رابطه‌ای برای تنش برشی بحرانی ارائه کردند. از مهم‌ترین پژوهش‌های بعد از آن، می‌توان کارهای میچنر و تورفر (۱۹۹۶) و سنفورد و ما (۲۰۰۱) و از نمونه پژوهش‌های نسبتاً جدیدتر در این زمینه می‌توان مطالعات دیکهاد و همکاران (۲۰۱۱)، وینتروپ و همکاران (۲۰۱۲)، پالینکاس و همکاران (۲۰۱۴)، کیمیاقلم و همکاران (۲۰۱۵) و مهتا و همکاران (۲۰۱۵) را نام برد. همچنین از نمونه مطالعاتی که در آنها به استفاده از شبکه عصبی مصنوعی در مدل‌سازی شار رسوبات معلق پرداخته شده می‌توان به تحقیق ژو و همکاران (۲۰۰۶) و ملیسی و همکاران (۲۰۱۱) اشاره کرد.

۲ روش تحقیق

پس از گردآوری داده‌های اندازه‌گیری تنش برشی موجود در ادبیات فنی، بررسی عملکرد شبکه عصبی مصنوعی بر روی مجموعه داده کیمیاقلم و همکاران (۲۰۱۵) انجام شد. در این مجموعه داده، با برداشت چندین نمونه رسوب طبیعی و دست-نخوده از کرانه‌های گوناگون رودخانه‌ای در کانادا به اندازه‌گیری ۱۳ ویژگی فیزیکی، مکانیکی و الکتروشیمیایی پرداخته شده است (جدول ۱). با توجه به گسترده بودن طیف پارامترهای بالقوه مؤثر بر تنش برشی بحرانی در این مجموعه داده، تعریف چه تعداد و کدامین داده‌ها به عنوان ورودی و خروجی در جعبه‌ابزار برازش عصبی (nftool)، از اهمیت بسیاری برخوردار است. از این‌رو، به واکاوی تأثیر ترکیبات مختلف پارامترهای مؤثر احتمالی به عنوان ورودی شبکه عصبی مصنوعی برآموزش شبکه اقدام شد. به عبارت دیگر، در تلاش‌های گوناگون، ارزیابی هر ترکیب دوتایی، سه‌تایی، چهارتایی و ترکیبات بزرگ‌تر محتمل از پارامترها به عنوان ورودی شبکه عصبی انجام شد تا بتوان به تصویری بهتر از تأثیر آن مجموعه پارامتر انتخابی بر تنش برشی بحرانی دست یافت. همچنین از پارامتر تنش برشی بحرانی به عنوان هدف در آموزش شبکه عصبی مصنوعی برای تمام ترکیبات ممکن پارامترهای ورودی استفاده شده است. در گام بعد، تعیین درصد داده‌های آموزشی، صحبت‌سنگی و آزمایش انجام شد و پس از بررسی‌های متعدد، ۷۰ درصد از کل داده‌ها به داده‌های آموزشی و ۱۵ درصد به هریک از داده‌های صحبت‌سنگی و آزمایش اختصاص یافت. در ادامه، تعیین تعداد نورون‌های لایه پنهان بررسی شد و پس از تلاش‌هایی متعدد در ساختن شبکه‌های با تعداد نورون‌های گوناگون، تعداد ۱۰ نورون در این لایه انتخاب گردید. سپس با استفاده از الگوریتم آموزشی لونبرگ-مارکواردت به آموزش شبکه عصبی مصنوعی پرداخته شد. با پایان یافتن آموزش و ساخته شدن شبکه عصبی، با به کارگیری دو پارامتر میانگین مربع خطای (MSE) و ضریب همبستگی (R)، عملکرد شبکه عصبی ساخته شده مورد ارزیابی قرار گرفته است.

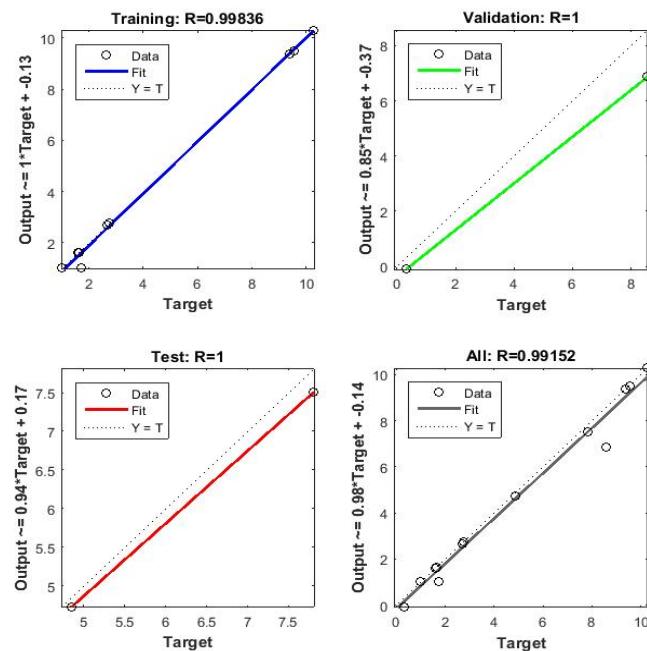
جدول ۱ خصوصیات اندازه‌گیری شده برای نمونه‌های رسوبی برداشت شده (کیمیاکلم و همکاران، ۲۰۱۵).

| Sample ID | CEC (meq/100g) | EC (dS/cm) | OM (%) | SAR | d_{50} (mm) | ρ_{dry} (kg/m ³) | C (kN/m ²) | $\tan \phi'$ | Sand % | Silt % | Clay % | w (%) | PI (%) | Soil type | τ_c (Pa) | K _d |
|-----------|-------------------|---------------|-----------|-------|------------------|--------------------------------------|---------------------------|--------------|-----------|-----------|-----------|----------|-----------|--------------|------------------|----------------|
| Red 1 | 30.7 | 0.72 | 2.2 | 0.992 | 0.015 | 1312 | 9.5 | 0.597 | 39 | 28 | 33 | 39 | 29 | CH | 9.38 | 1.327 |
| Red 2 | 17.2 | 0.352 | 1.0 | 0.89 | 0.045 | 1415 | 2.37 | 0.731 | 48 | 25 | 27 | 29 | 12 | CL | 0.98 | 1.53 |
| Red 3 | 31.29 | 0.855 | 9.0 | 0.92 | 0.0056 | 1209 | 10.4 | 0.624 | 18 | 41 | 41 | 44 | 34 | CH | 9.55 | 1.454 |
| Red 4 | 30.28 | 0.888 | 6.6 | 1.16 | 0.0081 | 1133 | 1.16 | 0.743 | 17 | 43 | 40 | 54 | 40 | CH | 1.72 | 0.797 |
| 2M(2-1) | 23.6 | 0.446 | 1.1 | 1.071 | 0.002 | 1567 | 8.3 | 0.551 | 14 | 44 | 42 | 28 | 21 | CL | 7.81 | 0.673 |
| 2M(2-2) | 23.1 | 0.462 | 1.0 | 1.075 | 0.002 | 1542 | 11 | 0.435 | 5 | 45 | 50 | 34 | 24 | CL | 10.25 | 0.641 |
| 8M(1-1) | 29.2 | 0.406 | 1.4 | 1.621 | 0.0004 | 1419 | 8.5 | 0.551 | 2 | 4 | 94 | 35 | 27 | CH | 4.85 | 0.325 |
| M(2-1) | 28.2 | 0.284 | 1.4 | 1.373 | 0.0011 | 1512 | 10 | 0.572 | 6 | 34 | 60 | 27 | 17 | CL | 8.57 | 0.898 |
| 8M(2-2) | 27.1 | 0.288 | 1.9 | 0.28 | 0.0013 | 1445 | 1.7 | 0.74 | 2 | 33 | 65 | 23 | 14 | CL | 1.62 | 8.674 |
| 8M(3-1) | 28.1 | 0.314 | 2.8 | 0.639 | 0.0015 | 1378 | 2 | 0.738 | 17 | 27 | 56 | 40 | 24 | CL | 2.68 | 0.98 |
| 8M(3-2) | 24.7 | 0.386 | 2.1 | 1.035 | 0.0017 | 1605 | 2.9 | 0.75 | 1 | 45 | 54 | 38 | 18 | CL | 2.74 | 0.42 |
| 8M(6-1) | 21.6 | 0.204 | 1.2 | 0.239 | 0.02 | 1843 | 2.4 | 0.897 | 39 | 37 | 24 | 17 | 13 | CL | 1.6 | 6.95 |
| 8M (7-1) | 26.3 | 0.206 | 1.0 | 0.358 | 0.0074 | 1747 | 1 | 0.869 | 25 | 50 | 25 | 22 | 5 | CL-ML | 0.31 | 3.683 |

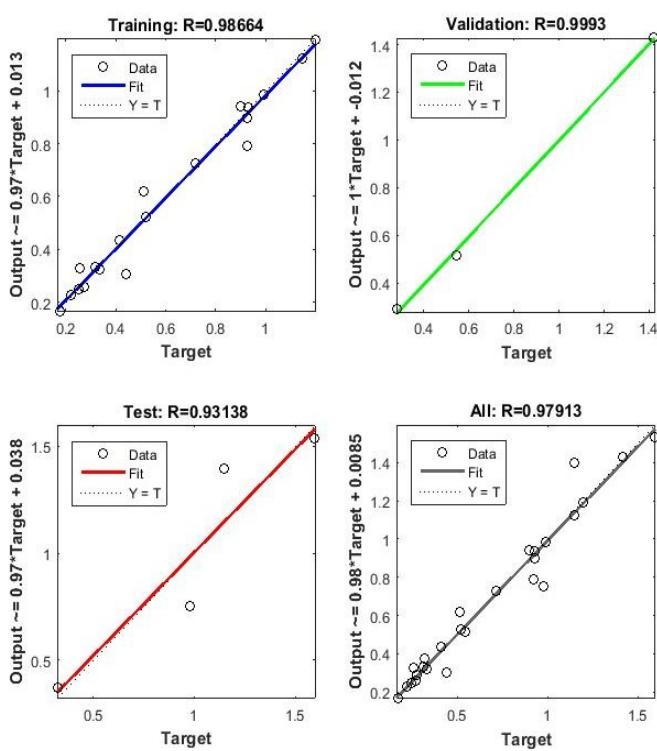
در گام بعد، برای بررسی عملکرد شبکه عصبی بر روی یک مجموعه داده دیگر و اطمینان از اتفاقی نبودن نتایج، نسبت به ساختن شبکه‌های عصبی گوناگون بر روی مجموعه داده‌های جیکوبز و همکاران (۲۰۱۰) اقدام گردید. این مجموعه داده که نتایج آزمایش فلوم فرسایش رسوبات مصنوعی را ارائه می‌دهد، از این حیث حائز اهمیت است که دارای تفاوت بنیادین و ماهیتی نسبت به داده‌های برداشت شده از نمونه‌های رسوب طبیعی همچون داده‌های کیمیاکلم و همکاران (۲۰۱۵) است. برای امکان مقایسه نتایج شبکه‌های عصبی بر روی این مجموعه داده با نتایج حاصل از مجموعه داده کیمیاکلم و همکاران (۲۰۱۵)، از جعبه‌بازار برآش عصبی با تعداد ۱۰ نورون در لایه پنهان و درصدهای پیش‌فرض داده‌های آموزشی، صحبت‌سنگی و آزمایش استفاده شده است که با معماری بهینه این مجموعه داده نیز منطبق است.

۳ نتیجه‌گیری

نمونه‌ای از عملکرد شبکه عصبی بر اساس پارامترهای موجود در مجموعه داده کیمیاکلم و همکاران (۲۰۱۵) و جیکوبز و همکاران (۲۰۱۰) در شکل‌های ۱ و ۲ مشاهده می‌شود. نتایج حاصل از این پژوهش به اختصار در ادامه آورده شده است.



شکل ۱ نمونه عملکرد خوب یک شبکه عصبی با تعداد ۱۰ نورون در لایه پنهان بر روی تمام پارامترهای جدول کیمیاکلم و همکاران (۲۰۱۵).



شکل ۲ نمونه عملکرد یک شبکه عصبی با تعداد ۱۰ نورون در لایه پنهان بر روی تمام پارامترهای مجموعه داده جیکوبز و همکاران (۲۰۱۰).

- در بررسی یک پدیده پیچیده مانند فرسایش که رابطه ریاضی دقیق و فراغیری میان علت و معلول آن در دسترس نیست، با استفاده از آموزش شبکه‌های عصبی مصنوعی می‌توان به وآکاوی الگوهای احتمالی میان پارامترهای بالقوه مؤثر پرداخت.
- همچنین با توجه به میسر نبودن ایجاد ارتباط میان طیف وسیع پارامترهای مؤثر بر تنش برشی با استفاده از اغلب روش‌های آماری مرسوم و ناکارآمدی برآش‌های دوپارامتره در به نمایش گذاشتن یک روند مشخص، از روش شبکه عصبی مصنوعی به عنوان یکی از روش‌های یادگیری ماشینی استفاده شد.
- روش ارائه شده در این مطالعه امکان یافتن یک رابطه منطقی میان پارامترهای اندازه‌گیری و تنش برشی بحرانی را فراهم آورده است.
- شبکه عصبی مصنوعی به واسطه قابلیت بالای آن در یادگیری تطبیقی، به خوبی توانسته است بر روی ترکیبات گوناگون از پارامترهای بالقوه مؤثر بر تنش برشی در همه مجموعه داده‌ها آموزش ببیند.

منابع

- Jacobs, W., Le Hir, P., Van Kesteren, W., & Cann, P. (2011). Erosion threshold of sand–mud mixtures. *Continental Shelf Research*, 31(10), S14-S25.
- Kimiaghaham, N., Clark, S. P., & Ahmari, H. (2016). An experimental study on the effects of physical, mechanical, and electrochemical properties of natural cohesive soils on critical shear stress and erosion rate. *International Journal of Sediment Research*, 31(1), 1-15.
- Parchure, T. M., & Mehta, A. J. (1985). Erosion of soft cohesive sediment deposits. *Journal of Hydraulic Engineering*, 111(10), 1308-1326.
- van Prooijen, B. C., & Winterwerp, J. C. (2010). A stochastic formulation for erosion of cohesive sediments. *Journal of Geophysical Research: Oceans*, 115(C1).
- Winterwerp, J. C., Kesteren, W. G. M., Prooijen, B., & Jacobs, W. (2012). A conceptual framework for shear flow-induced erosion of soft cohesive sediment beds. *Journal of Geophysical Research: Oceans*, 117(C10).