

مدل سازی جریان غلیظ با استفاده از روش درخت تصمیم

بهزاد وحدتی

کارمند سازمان آب و برق خوزستان

چکیده

جریان های غلیظ یکی از عوامل مهم در فرآیند رسوب گذاری در مخازن سدها می باشند. افزایش رسوب گذاری در مقابل سد، ظرفیت ذخیره سازی آن را کاهش می دهد و چالش های عملیاتی قابل توجهی را ایجاد می کند. درک دینامیک سیالات جریان های غلیظ و الگوهای رسوبی مرتبط جهت مدیریت مخزن سد بسیار کاربردی می باشد. براین اساس در این تحقیق، مقادیر دبی جریان غلیظ در کانالی آزمایشگاهی با استفاده از روش درخت تصمیم به صورت عددی مورد بررسی قرار گرفته است. روند کار به این صورت بود که با استفاده از روش درخت تصمیم، داده های آزمایشگاهی مورد بررسی و پیش بینی قرار گرفتند و سپس با استفاده از مقادیر خطا و رگسیون، به ارزیابی عملکرد این مدل ساز پرداخته شد که نتایج نسبتاً مناسبی به دست آمد.

واژگان کلیدی : جریان های غلیظ، رسوب گذاری، مخازن سدها، درخت تصمیم

در دهه‌های گذشته تعداد سدهای ساخته شده برای کنترل سیل، تامین آب، تولید برق، تفریحات و غیره افزایش یافته است. وجود رسوبات معلق در جریان ورودی به سمت مخزن باعث رسوب‌گذاری در مخزن سد می‌شود (Brandt, 1999). پدیده ته نشینی، حجم ذخیره مخزن را کاهش می‌دهد، بنابراین طول عمر سد کمتر از زمان مورد انتظار که توسط مهندسين تعیین شده خواهد بود (Fan and Morris, 1992). بررسی‌های انجام شده نشان داد که انتقال رسوب به وسیله جریان‌های غلیظ عامل اصلی ایجاد رسوب در مخازن می‌باشد (Alves et al, 2008). جریان‌های غلیظ، جریان‌های گرانثی حاوی ذرات معلق در یک سیال محیطی می‌باشند (Alavian et al, 1992). نیروهای اصلی موثر در این پدیده، نیروی گرانش و اختلاف چگالی بین جریان رسوبی و سیال محیطی است (Alexander and Mulder, 2002). او اهمیت جریان‌های غلیظ در مخازن سدها را برجسته کرد و همچنین این جریان‌ها را به صورت تجربی مورد مطالعه قرار داد (Bell, 1942). بعدها بسیاری از محققین با استفاده از روش‌های تجربی و عددی به بررسی ویژگی‌های جریان غلیظ پرداختند و مطالعاتی را نیز به ثبت رساندند (Kneller, 2003). برخی از مطالعات تأثیر برخی عوامل بر جریان‌های غلیظ را مانند زبری و شیب بستر را بررسی کردند. او به صورت تجربی رفتار جریان‌های غلیظ را در نزدیکی یک انتقال شیب مطالعه کرد (Garcia, 1993). دو جریان غلیظ رسوبی و شور ایجاد شد و سرعت جریان، غلظت رسوب و پروفیل‌های چگالی اضافی اندازه‌گیری شد. همچنین او به این نتیجه رسید که حباب در ناحیه فوق بحرانی بیشتر از ناحیه زیر بحرانی است. آنها از فلورسانس ناشی از لیزر برای تجسم جریان چگالی سطح ناهموار استفاده کردند (Peters and Venart, 2000). آنها نشان دادند که وجود ناهمواری بستر باعث کاهش سرعت و میانگین غلظت هد می‌شود. آنها به بررسی برخی آزمایش‌ها برای مطالعه ویژگی‌های جریان و رسوب‌گذاری جریان‌های غلیظ با چگالی بالا پرداختند (Baas et al, 2004). آنها اثر زبری بستر و چگالی اولیه سیال را بر سینماتیک جریان گرانثی نمکی بر اساس کار تجربی تجزیه و تحلیل کردند (Nogueira et al, 2013). آنها به این نتیجه رسیدند که سرعت جریان ورودی، غلظت رسوب و توزیع اندازه دانه پارامترهای مهمی در دینامیک فعلی، تکامل آن از نظر مکانی و زمانی می‌باشند (Lee and Yu, 1997). فلیکس و همکاران [۲۳] از سه مجموعه آزمایش استفاده کردند که در آنها یک رسوب چسبنده با غلظت حجمی اولیه ۱۶ درصد کائولینیت و یک رسوب غیر چسبنده با دو غلظت ۴ و ۲۸ درصد سیلیس در نظر گرفته شد. آنها از یک پروفیل سرعت سنجی داپلر اولتراسونیک و یک متر غلظت بالا اولتراسونیک برای اندازه‌گیری پروفیل‌های سرعت و غلظت به طور همزمان در ارتفاعات مختلف استفاده کردند (Felix et al, 2005). آنها آزمایش‌هایی بر روی جریان‌های غلیظ نمکی انجام دادند (Firoozabadi et al, 2009). در این آزمایش‌ها میزان غلظت ورودی، دبی‌ها و شیب‌های بستر متفاوت انجام شد. در دهه اخیر، استفاده از روش‌های عددی/محاسباتی در مهندسی هیدرولیک، منابع آب و هیدرولوژی افزایش یافته است (Bilgil and Altun, 2008). آنها از یک شبکه عصبی مصنوعی سه لایه (ANN)، بر اساس الگوریتم یادگیری لونیبرگ-مارکوارت، برای تخمین ضریب اصطکاک در جریان‌های کانال باز استفاده کردند (Yuhong and Wenxin, 2009). آنها از الگوریتم پس انتشار ANN (BP) برای پیش‌بینی نرخ جریان در یک جریان کانال باز مرکب استفاده کردند (Mrutyunjaya et al, 2011). آنها میدان سرعت را در یک کانال خمشی ۹۰ درجه با استفاده از هوش مصنوعی، روش تحلیلی، تجربی و عددی بررسی کردند. آنها دریافتند که تمامی مدل‌های ذکر شده با داده‌های تجربی تطابق خوبی دارند و همچنین مدل ANN و روش عددی سرعت را بهتر از حل تحلیلی پیش‌بینی می‌کنند (Baghalian et al, 2012). آنها با استفاده از روش ANN طول پرش هیدرولیکی را در کانال U شکل تخمین زدند

(Houichi et al, 2013). با توجه به مطالب ارایه شده در این مطالعه از داده‌های یک مدل تجربی استفاده می‌کند به این صورت که متغیرهای شیب، غلظت و دبی ورودی به عنوان ورودی و دبی کاهش یافته به عنوان خروجی در نظر گرفته شده و با استفاده از مدل‌ساز درخت تصمیم، اقدام به مدل‌سازی جریان غلیظ شد.

۲- مواد و روش‌ها

این قسمت شامل دو بخش می‌باشد به این صورت که در بخش اول به ارایه نحوه برداشت داده‌ها پرداخته و بخش بعد نیز به بیان توضیحاتی درباره درخت تصمیم پرداخته شده است.

۲-۱- داده‌های مورد بررسی

در این مقاله از داده‌های آزمایشگاهی (Derakhshannia et al, 2021) جریان غلیظ که در دانشکده آب دانشگاه شهید چمران برداشت شده، استفاده شده است. برای این منظور سه متغیر ورودی استفاده شده که عبارتند از شیب کف، غلظت ورودی و دبی ورودی و خروجی معرفی شده به نرم‌افزار دبی خروجی کاهش یافته تحت تاثیر موانع نفوذپذیر بود.

۲-۲- درخت تصمیم

ارزش یک متغیر هدف را می‌توان با استفاده از مقادیر مجموعه‌ای از متغیرها پیش‌بینی کرد. یکی از روش‌هایی که در این زمینه کارا می‌باشد، روش درخت تصمیم است. درخت تصمیم از سه نوع گره تشکیل شده است: گره ریشه، گره داخلی و گره برگ. گره ریشه و گره داخلی نشان دهنده یک تست تقسیم‌باینری بر روی یک ویژگی هستند در حالی که گره برگ نشان دهنده نتیجه طبقه بندی است و بنابراین یک برچسب هدف طبقه بندی را نگه می‌دارد. علاوه بر این، اعداد داخل پرانتز در انتهای هر گره برگ، تعداد رکوردهای داده در این برگ را نشان می‌دهد. اگر برخی از برگ‌ها ناخالص باشند (یعنی برخی از رکوردها به اشتباه در این گره طبقه‌بندی شوند)، تعداد رکوردهای طبقه‌بندی شده اشتباه پس از یک اسلش داده می‌شود. تولید درخت تصمیم به طور کلی یک فرآیند دو مرحله‌ای است، یعنی یادگیری و طبقه بندی. در فرآیند یادگیری، داده‌های جمع آوری شده به دو زیر مجموعه تقسیم می‌شوند، مجموعه آموزشی و مجموعه تست. ایجاد مجموعه آموزشی و مجموعه تست بخش مهمی از ارزیابی مدل های داده کاوی است. معمولاً اکثر رکوردهای داده در پایگاه داده به صورت دلخواه برای آموزش انتخاب می‌شوند و از رکوردهای داده باقی مانده برای تست استفاده می‌شود. توجه داشته باشید که مجموعه آموزشی و مجموعه تست باید از یک جمعیت باشند اما باید از هم جدا باشند. سپس یک الگوریتم تولید درخت تصمیم، داده های آموزشی را به عنوان ورودی می‌گیرد و یک درخت تصمیم را خروجی می‌کند. الگوریتم‌های متداول تولید درخت تصمیم شامل ID3، درختان طبقه‌بندی و رگرسیون (CART) و C4.5 می‌باشد (Quinlan, 1986). در بسیاری از مطالعات از C4.5 برای ساخت درخت تصمیم به دلیل انعطاف‌پذیری و کاربرد وسیع آن برای انواع مختلف داده‌ها استفاده شده است. در فرآیند طبقه‌بندی، صحت درخت تصمیم به دست آمده ابتدا با انجام پیش‌بینی‌هایی در برابر داده‌های آزمون ارزیابی می‌شود. دقت درخت تصمیم با مقایسه مقادیر هدف پیش‌بینی شده و مقادیر هدف واقعی داده‌های تست اندازه‌گیری می‌شود. اگر دقت قابل قبول در نظر گرفته شود، درخت تصمیم را می‌توان به مجموعه داده‌های جدید برای طبقه بندی و پیش‌بینی اعمال کرد. در غیر این صورت باید دلیل آن شناسایی و راه حل های مربوطه برای رفع مشکلات اتخاذ شود (شکل (۱)).

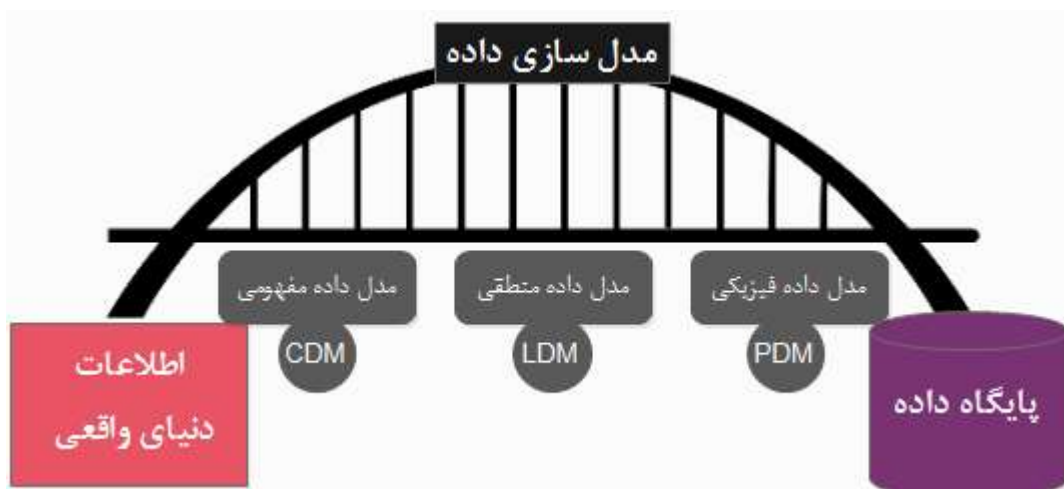
هشتمین کنفرانس بین المللی تحقیقات بین رشته‌ای در عمران، معماری و مدیریت شهری قرن ۲۱



شکل ۱: درخت تصمیم

۳- نتایج


مدل‌سازی داده فرآیند ایجاد مدل برای ذخیره داده‌ها در پایگاه داده است. مدل‌سازی داده شامل نمایش مفهومی داده، ارتباط بین داده‌های مختلف و قوانین می‌شود. مدل‌سازی داده‌ها به نمایش بصری داده‌ها کمک می‌کند و قوانین کسب و کار، نظارتی و سیاست‌های دولت در مورد داده‌ها را اعمال می‌کند. مدل‌سازی داده ضمن اطمینان از کیفیت داده‌ها، سازگاری در نام‌گذاری قراردادها، مقادیر پیش‌فرض، معنانشناسی و مواردی از این دست را امکان‌پذیر می‌سازند. براین‌اساس در دهه‌های اخیر بسیار این علم مورد توجه محققین قرار گرفته است.



شکل ۲: نمونه‌ای از مدل‌سازی داده‌ها


با توجه به مطالب ارایه شده در این مقاله از سه متغیر ورودی که عبارتند از شیب کف، غلظت ورودی و دبی ورودی و خروجی معرفی شده به نرم‌افزار دبی خروجی کاهش یافته تحت تاثیر موانع نفوذپذیر جهت مدل‌سازی با درخت تصمیم استفاده شد.

براین اساس در شکل (۳) به ارایه میزان اختلاف ایجاد شده بین داده‌های آزمایشگاهی (واقعی) و پیش‌بینی شده پرداخته شده است.



شکل ۱: اختلاف داده‌های واقعی و پیش‌بینی شده

همان‌طور که در شکل (۳) مشخص است مقادیر اختلاف ناچیز می‌باشد. اما میزان خطا به تنهایی برای بررسی کارایی یک روش مدل‌ساز کافی نبوده و لازم است مقادیر رگرسیون تعیین گردد، به همین منظور در شکل (۴) به ارایه مقدار رگرسیون حاصله پرداخته شده است.



شکل ۴: رگسیون داده‌ها

همان‌طور که در شکل (۴) مشخص است خط رد شده از بین داده‌ها، برازش مناسبی داشته است. که این دو پارامتر نشان می‌دهد کارایی مناسبی روش درخت تصمیم در مدل‌سازی داده‌ها دارد.

۴- نتیجه‌گیری

مدل‌سازی داده‌ها به نحوه مدیریت، ارزیابی و اندازه‌گیری جریان‌های داده‌ای اشاره دارد که قرار است به پایگاه داده وارد یا از آن خارج شوند. از آنجایی که وظیفه ساخت فضای لازم برای داده‌ها بر عهده دانشمندان علم داده است، مدل‌سازی داده‌ها یکی از مهم‌ترین بخش‌های یک پروژه بزرگ داده‌ای است. مدل‌سازی داده‌ها به ساختارمند کردن فضای داده‌ای و ارزیابی فاکتورهایی که برای مدل‌سازی داده‌ها به آن‌ها نیاز است اشاره دارد. به‌طور خلاصه، مدل‌سازی داده‌ها به مدیریت داده‌ها در یک سازمان یا علم اشاره دارد. براین اساس در این مقاله تلاش شده با استفاده از داده‌های ارایه شده در یک طرح آزمایشگاهی اقدام به مدل‌سازی داده‌ها شود. داده‌های آزمایشگاهی جریان غلیظ نمکی به کار رفته شامل شیب، غلظت و دبی ورودی و خروجی آن نیز دبی کاهش یافته بود. از این داده‌ها استفاده شد و با استفاده از درخت تصمیم به مدل‌سازی داده‌ها پرداخته شد که با تحلیل خروجی این مدل‌ساز، تطابق خوبی در مدل‌سازی داده‌ها توسط این مدل مشاهده شد.

مراجع

- 1- Brandt SA (1999) Reservoir distillation by means of hydraulic flushing. Ph.D. thesis, Inst. of Geog. Faculty of Sci. University of Copenhagen, pp 204.
- 2- Fan J, Morris G (1992) Reservoir sedimentation. I: delta and density current. J Hydraul Eng 118:354–369.
- 3- Alves E, Gonzalez J, Freire, P, Cardoso H (2008) Experimental study of plunging turbidity currents in reservoirs. In: Proceedings of river flow, pp 1157–1164.
- 4-Alavian V, Jirka GH, Denton RA, Johnson MC, Stefan HG (1992) Density currents entering lakes and reservoirs. J Hydraul Eng 118:1464–1489.
- 5- Alexander J, Mulder T (2002) Experimental quasi-steady density currents. Mar Geol 186:195–210.
- 6- Bell HS (1942) Some evidence regarding the kind and quantity for sediment transported by density current. Eos Trans 23:67–73.
- 7- Kneller Ben (2003) “The influence of flow parameters on turbidite slope channel architecture. Mar Pet Geol 20(2003):901–910.
- 8- Garcia M (1993) Hydraulic jumps in sediment-driven bottom current. J Hydraul Eng 119:1094–1117.
- Peters WD, Venart JES (2000) Visualization of rough-surface gravity current flows using laser-induced fluorescence. In: 9th international symposium on flow visualization.
- 9- Baas JH, Kesteren WV, Postma P (2004) Deposits of depletive high-density turbidity currents: a flume analogue of bed geometry, structure and texture. Sedimentology 51:1053–1088.
- 10- Nogueira HIS, Adduce C, Alves E, Franca MJ (2013) Analysis of lock-exchange gravity currents over smooth and rough beds. J Hydraul Res 51:417–431.
- 11- Lee HY, Yu WS (1997) Experimental study of reservoir turbidity current. J Hydraul Eng 123:520–528.
- 12- Felix M, Sturton S, Peakall J (2005) Combined measurements of velocity and concentration in experimental turbidity currents. Sediment Geol 179:31–47
- 13- Firoozabadi B, Afshin H, Aram E (2009) Three-dimensional modeling of density current in a straight channel. J Hydraul Eng 135:393–402.
- 14- Bilgil A, Altun H (2008) Investigation of flow resistance in smooth open channels using artificial neural networks. Flow Meas Instrum 19:404–408
- 15- Yuhong Z, Wenxin H (2009) Application of artificial neural network to predict the friction factor of open channel flow. Commun Nonlinear Sci Numer Simul 14:2373–2378.
- 16- Mrutyunjaya S, Khatua KK, Mahapatra SS (2011) A neural network approach for prediction of discharge in straight compound open channel flow. Flow Meas Instrum 22:438–446.
- 17- Baghalian S, Bonakdari H, Nazari F, Fazli M (2012) Closed-form solution for flow field in curved channels in comparison with experimental and numerical analyses and artificial neural network. Eng Appl Comput Fluid 6:514–526.
- 18- Houichi L, Dechemi N, Heddam S, Achour B (2013) An evaluation of ANN methods for estimating the length of hydraulic jumps in U-shaped channel. J Hydroinform 15:147–154.
- 19- Derakhshannia, M., Ghomeshi, M., Eslamian, S. S., & Kashefipour, S. M. (2021). Investigation of the Performance of Permeable Obstacles on the Salty Head Density Current. *Water Resources*, 14(50), 31-44.
- 20- Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1(1), 81-106.
- Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (2017). *Classification and regression trees*. Routledge.
- 21- Quinlan, J. R. (1995). Programs for Machine Learning, Morgan Kaufmann, San Mateo, California 10(3), 475-476.