

پیش بینی دبی جریان در مقاطع مرکب، مقایسه روش‌های داده محور و تجربی

معین بهرام پور^۱، غلامعباس بارانی^۲، محمد ذونعمت کرمانی^۳

مقاله پژوهشی-کاربردی

تاریخ ارسال: ۱۳۹۷/۰۴/۱۶

تاریخ پذیرش: ۱۳۹۷/۰۷/۰۱

چکیده

پیش‌بینی دبی رودخانه‌ها در شرایط پدیدار شدن وضعیت کانال مرکب یکی از پارامترهای مهم در مهندسی سیلاب و رودخانه‌ها می‌باشد. در این تحقیق با استفاده از رویکردهای داده محور از جمله شبکه عصبی مصنوعی (ANN) و ماشین‌های بردار پشتیبان (کلاس بندی) (SVM) و رگرسیون (SVR) و همچنین روش تجربی کانال تقسیم شده بروش تقسیم بندی عمودی (DCM) دبی کانال مرکب پیش‌بینی شده است. برای این هدف تعداد ۱۵۰ داده آزمایشگاهی از ۶ منبع علمی گردآوری شد. این داده‌ها با استفاده از روش اعتبار سنجی متقابل k-تایی به چهار دسته بیست و پنج درصدی تقسیم بندی شدند. در هر مدل‌سازی در رویکردهای داده محور، آزمون مدل توسط یک دسته از داده‌ها صورت گرفت. پس از میانگین گرفتن از نتایج یکسان در هر رویکرد داده محور، نتایج برتری روش SVR را نشان داد. این روش با داشتن بیشترین مقدار ضریب تعیین (R^2) و ضریب کارائی مدل نش ساتکلیف (NS) (بترتیب برابر با ۰/۹۲۸۷۵ و ۰/۸۹۸۰۷۵) و داشتن کمترین مقدار ریشه میانگین مجذور خطا (RMSE) و میانگین درصد خطای مطلق (MAPE) (بترتیب برابر با ۰/۰۸۴۳۵ و ۰/۲۳/۸۹) و همچنین با داشتن بیشترین درصد برتری نسبی RMSE نسبت به شبکه عصبی مصنوعی در پیش‌بینی دبی کانال مرکب موفق‌تر از دیگر روش‌ها عمل کرده است.

واژه‌های کلیدی: پیش‌بینی دبی، شبکه عصبی مصنوعی، کانال تقسیم شده، ماشین بردار پشتیبان، مقاطع مرکب،

SVR

^۱ دانشجوی کارشناسی ارشد سازه‌های آبی دانشگاه شهید باهنر کرمان، کرمان، ایران، ۰۹۱۳۳۹۰۷۶۶۸ moin.bahram@gmail.com

^۲ استاد بخش مهندسی عمران دانشگاه شهید باهنر کرمان، کرمان، ایران. gab@uk.ac.ir

^۳ دانشیار بخش مهندسی آب دانشگاه شهید باهنر کرمان، کرمان، ایران. zounemat@uk.ac.ir (نویسنده مسئول)

مقدمه

برآورد این پارامترها توسعه داده شده است. از جمله می توان به رویکردهای تجربی، آزمایشگاهی، عددی و داده محور اشاره کرد. در این بین با توجه به اهمیت موضوع می توان به چندین مورد از روش های پیشنهادی در مطالعه دیگر محققان اشاره کرد. (Azamathulla & Zahiri, 2012) در تحقیقی با استفاده از ۳۹۴ داده فیزیکی معتبر دبی اشل توانستند با استفاده از تلفیق روش تجربی کانال تقسیم شده (DCM) و الگوریتم ژنتیک خطی که یکی از شاخه های محاسبات نرم می باشد، دبی کانال مرکب را برآورد کنند. این روش در مقایسه با روش های تجربی دیگر از موفقیت بیشتری در برآورد دبی برخوردار است. (Sahu et al., 2011) با در نظر گرفتن داده های فیزیکی آزمایشگاه های معتبر و روش های برآورد دبی کانال مرکب در یک بعد (۱- کانال تقسیم شده ۲- روش ارتباط بین دو کانال (COHM) ۳- روش تبادل دبی (EDM)) و تکنیک شبکه عصبی اقدام به برآورد دبی کانال مرکب کردند. نتایج نشان داد که رویکرد هوش مصنوعی در مقایسه با سایر روش های یک بعدی در ارزیابی با داده های واقعی، بیشترین ضریب همبستگی و کمترین خطای مطلق را داشته است. (Naik et al., 2017) به مطالعه برآورد رابطه دبی اشل در کانال مرکب پرداختند. برای این هدف از روش های یک بعدی برآورد دبی (۱- کانال تقسیم شده (DCM) ۲- روش ارتباط بین دو کانال (COHM) ۳- روش تبادل دبی (EDM))، و رویکرد شبکه عصبی مصنوعی چند لایه استفاده کردند. نتایج نشان داد که شبکه عصبی در مقایسه با روش ارتباط و روش تبادل دبی از نظر نتایج آماری کمی بهتر عمل می کند اما در مقایسه با روش کانال تقسیم شده از دقت بیشتری برخوردار است. (Noori et al., 2015) با استفاده از سه مدل داده محور شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و سیستم عصبی فازی (ANFIS) اقدام

تعیین دبی جریان در رودخانه ها یکی از پارامترهای کلیدی مدل سازی ریاضی در پروژه های طراحی مهندسی رودخانه می باشد. رودخانه ها در پایین دست انشعابات خود سیلاب دشت های وسیعی دارند که در هنگام سیل مناطق اطراف و حریم بستر را تحت تاثیر قرار می دهند. در مواقع سیلابی تغییرات شدیدی در عمق جریان و زبری در کانال اصلی و سیلاب دشت اتفاق می افتد. در حین این تغییرات گرادیان بزرگی از تغییرات سرعت در سطح مقطع رخ می دهد. این تغییرات سرعت باعث تغییر مومنوم در نقاط واصل بین سیلاب دشت و کانال اصلی می شود (Azamathulla & Zahiri, 2012). بسیاری از مسائل کاربردی در مهندسی رودخانه احتیاج به پیش بینی دقیق جریان در کانال های مرکب دارد. همچنین تعیین شرایط جریان محلی برای آگاهی از نسبت فرسایش و رسوب گذاری به دبی کل مربوط می شود. دقت پیش بینی ظرفیت انتقال در کانال مرکب دقیقا برای طرح کاهش سیلاب می باشد. سیل زمانی اتفاق می افتد که دبی بطور ناگهانی در سیلاب دشت ها پخش شود (Sahu et al., 2011).

دقت پیش بینی سطح سیلاب و سرعت آن در مدیریت بهتر رودخانه از اهمیت بالایی برخوردار است. کنترل سیلاب در رودخانه ها باعث کاهش خطرات زیست محیطی، انسانی و اقتصادی می شود. که آگاهی از رفتار رودخانه ها پیش نیاز چنین امری می باشد (Fernandes et al., 2015). مفهوم کانال باز مرکب یک راه حل دقیق و جدید برای مدل سازی جریان های طبیعی می باشد که اخیرا توسعه داده شده است. مطالعه دبی جریان، توزیع سرعت، توزیع تنش برشی از پارامترهای اصلی مطالعه در کانال باز مرکب می باشد. با توجه به این مفهوم مدل سازی و برآورد پارامترهای ذکر شده روش های متعددی برای

سیلاب دشت (متر) (m) ، $n(mc)$ ضریب مانینگ کانال اصلی، $n(fp)$ ضریب مانینگ سیلاب دشت، $S1$ شیب دیواره جانبی کانال اصلی (برحسب درجه نسبت به افق)، $S2$ شیب دیواره جانبی سیلاب دشت (برحسب درجه نسبت به افق)، $S0$ شیب طولی کانال مرکب $(\frac{m}{m})$ ، Q دبی جریان کانال مرکب (مترمکعب بر ثانیه $\frac{m^3}{s}$).

تعداد ۱۵۰ داده آزمایشگاهی از ۶ مقاله معتبر علمی (۱۰ و ۹ و ۸ و ۷ و ۶ و ۵) گردآوری شده است. جدول ۱ دامنه و میانگین این داده‌ها را نمایش می‌دهد. داده‌های جمع آوری شده با استفاده از روش اعتبارسنجی متقابل k -تایی به چهار دسته بیست و پنج درصدی تقسیم بندی شدند. در هر رویکرد داده محور چهار بار مدل‌سازی صورت گرفته است. در هر مدل‌سازی هفتاد و پنج درصد از داده‌ها برای آموزش مدل و بیست و پنج درصد باقی مانده برای واسنجی آن استفاده شده است. که در هر مرحله تست مدل با استفاده از یک دسته بیست و پنج درصدی انجام شده است. در نهایت برای ارائه نتایج از مدل‌های یکسان در هر رویکرد هوشمند، میانگین گرفته شده است. هدف از این کار شرکت دادن همه داده‌ها در آموزش و تست در هر رویکرد داده محور می‌باشد.

روش‌های مدل‌سازی مورد استفاده

روش تجربی کانال تقسیم شده (DCM)

از رویکردهای برآورد دبی کانال‌های مرکب استفاده از ساختار جریان در شبیه‌سازی فرآیند واکنش بین کانال اصلی و سیلاب دشت‌ها با دقت زیاد می‌باشد (Sahu et al., 2011). یکی از روش‌های معمول و رایج در محاسبه دبی در کانال مرکب استفاده از روش مقطع تقسیم شده است. در این روش برای محاسبه دبی کانال اصلی و سیلاب دشت‌ها، کانال مرکب را با استفاده از خط‌های عمودی (vertical)، افقی (horizontal) و مایل (diagonal)

به برآورد ضریب پراکندگی طولی در کانال مرکب و مقایسه با داده‌های فیزیکی کردند. رابطه بین این روش‌ها توسط آنالیز عدم قطعیت بروش مونت کارلو صورت گرفت. نتایج نشان داد که روش ماشین بردار پشتیبان نسبت به دو روش دیگر از عدم قطعیت کمتری برخوردار است. و مدل سیستم عصبی فازی در ارزیابی توسط داده‌های فیزیکی بهتر از شبکه عصبی مصنوعی عمل کرده است.

با توجه به اهمیت موضوع و روش‌های مطرح شده توسط محققین دیگر در این مطالعه با استفاده از سه روش داده محور شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و رگرسیون بردار پشتیبان (SVR) و روش تجربی کانال تقسیم شده (DCM) اقدام به پیش‌بینی دبی کانال مرکب شده است. برای این منظور داده‌های فیزیکی گردآوری شده از منابع معتبر علمی بطور مستقیم بعنوان ورودی وارد این روش‌ها شدند. در نهایت درصد برتری روش‌های مورد استفاده نسبت به شبکه عصبی مصنوعی محاسبه خواهد شد.

مواد و روش‌ها


داده‌های مورد استفاده

شکل ۱ سطح مقطع کانال مرکب متقارن و مشخصات فیزیکی آنرا نمایش می‌دهد. سطح مقطع کانال‌های باز مرکب شامل کانال اصلی و سیلاب دشت‌ها می‌باشد. در کانال‌های متقارن هر دو سیلاب دشت‌های چپ و راست دیده می‌شود. اما کانال‌های نامتقارن تنها دارای یک سیلاب دشت چپ یا راست می‌باشد. پارامترهای مورد استفاده در کانال‌های مرکب در مدل‌های آزمایشگاهی بشرح زیر می‌باشد. B = عرض سطح سیلاب دشت (متر) b ، عرض سطح کانال اصلی (متر) h ، ارتفاع نقاط ساحل رودخانه از کف کانال اصلی (متر) H ، ارتفاع جریان از کف کانال اصلی (متر) $H-h$ ، ارتفاع جریان در

بندی‌ها دبی با استفاده از معادلات شزی و یا مانینگ محاسبه شده و در نهایت مقدار دبی کل از جمع دبی‌های زیر تقسیم بندی‌ها برآورد می‌شود. معادله ۱ فرمول مانینگ مورد استفاده در این روش برآورد دبی را نمایش می‌دهد.

تقسیم بندی می‌کنند. شکل ۲ این سه نوع تقسیم بندی را نمایش می‌دهد.

این تقسیم بندی‌ها در محل نقاط ساحل رودخانه انجام می‌شود و کانال اصلی و سیلاب دشت‌های چپ و راست از هم جدا می‌شوند. در هر یک از این زیر تقسیم



شکل ۱ سطح مقطع عرضی کانال مرکب و مشخصات فیزیکی آن (Sahu et al., 2011)


جدول ۱ خصوصیات آماری داده‌های گردآوری شده

پارامترهای داده‌های جمع آوری شده	خصوصیات آماری داده‌ها	Niek et al., 2011	Hosseini 2004	Atabay et al., 2006	Mohanty et al., 2014	Knight & Demetriou 1983	Youesi et al., 2013
B	min-max	۰/۰-۰۹۹/۹	۰/۴۶-۴/۱	۰/۴۶-۴/۱	۰/۲-۷۵/۶۶	۱-/۷۶ ۰/۰۳۸	۰/۰-۲۲۸/۴
	mean	۰/۳۱۸۸	۱/۷۵۹	۱/۱۸۸	۱/۵۵	۰/۳۶۵۵	۰/۳۹
b	min-max	۰/۱-۳۰۴/۵	۰/۱-۲۹/۵	۰/۱-۲۹/۵	۰/۱-۲/۵	۰/۰-۱۵۲/۴	۰/۰-۱۵۲/۴
	mean	۰/۵۲۵	۱/۱۸۷	۰/۵۳۲	۰/۶۵۷	۰/۱۹	۰/۳۸
h	min-max	۰/۰-۰۵/۱۵	۰/۰-۱۲/۱۵	۰/۰-۱۲/۱۵	۰/۰-۱۵/۲۲	۰-/۲۲ ۰/۰۷۶	۰/۰-۰۷/۱۸
	mean	۰/۰۷۵	۰/۱۴	۰/۱۲۶	۰/۱۸۲	۰/۱	۰/۱۷
H	min-max	۰/۰-۰۵۲/۳	۰/۰-۱۳۵/۳	۰/۰-۱۴/۱۶	۰/۰-۱۵/۴۴	۰-/۴۴ ۰/۰۸۵	۰/۰-۱۰/۳۷
	mean	۰/۱۱	۰/۱۹	۰/۱۴	۰/۲۵	۰/۱۴	۰/۲۶
H-h	min-max	۰-/۱۵ ۰/۰۰۲۶	۰/۰-۰۰۶/۱۵	۰-/۰۴ ۰/۰۰۶	۰-/۲۲ ۰/۰۰۴	۰-/۲۱ ۰/۰۰۹	۰-/۱۹ ۰/۰۰۲
	mean	۰/۰۳	۰/۰۴	۰/۰۲	۰/۰۷	۰/۰۴	۰/۰۸
n(mc)	min-max	۰/۰۱۱	۰/۰۱	۰/۰۱	۰/۰۱	۰-/۰۱۲ ۰/۰۱	۰-/۰۲۴ ۰/۰۱۲
	mean	۰/۰۱۱	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱۱	۰/۰۲۳
n(fp)	min-max	۰/۰۱۱	۰/۰-۰۱/۰۱۱	۰-/۰۱۱ ۰/۰۱	۰/۰۱	۰-/۰۱۲ ۰/۰۱	۰-/۰۶۵ ۰/۰۱۲
	mean	۰/۰۱۱	۰/۰۱	۰/۰۱	۰/۰۱	۰/۰۱۱	۰/۰۴۴
S1	min-max	۹۰-۴۵	۹۰-۴۵	۹۰-۴۵	۹۰-۲۷	۹۰-۲۷	۹۰
	mean	۸۴/۳۷	۵۶/۶۱	۸۱	۵۹/۷۸	۸۴/۷۵	۹۰
S2	min-max	۹۰	۹۰-۴۵	۹۰	۹۰-۴۵	۹۰	۹۰
	mean	۹۰	۶۵/۳۲	۹۰	۷۷/۱۴	۹۰	۹۰
S0	min-max	۰-/۰۰۹۶ ۰/۰۰۱	۰-/۰۰۹۴ ۰/۰۰۱	۰-/۰۱۸ ۰/۰۰۱	۰-/۰۰۱ ۰/۰۰۰۹	۰-/۰۰۱ ۰/۰۰۰۹	۰-/۰۰۰۹ ۰/۰۰۰۸
	mean	۰/۰۰۳	۰/۰۰۲	۰/۰۰۹	۰/۰۰۹	۰/۰۰۰۹	۰/۰۰۰۸۸
Q	min-max	۰-/۸۳۴ ۰/۰۰۵	۱-/۱۱۴۱ ۰/۰۱۳۴	۰-/۲۰۲۱ ۰/۰۲۶	۱-/۱۱۴ ۰/۰۰۳	۱-/۱۰۳۴ ۰/۰۰۴۸	۰,۰۸- ۰/۰۰۹
	mean	۰/۰۸۹	۰/۳۳۲	۰/۰۶۴	۰/۳۱۹	۰/۱۱۶	۰/۰۵۴

$$Q = \sqrt{S} \left(\frac{1}{n_{mc}} A_{mc}^{\frac{5}{3}} P_{mc}^{-\frac{2}{3}} + \frac{1}{n_{fp}} A_{fp}^{\frac{5}{3}} P_{fp}^{-\frac{2}{3}} \right) \quad (1)$$

دشت‌ها، A_{mc} = مساحت سطح قطع کانال اصلی، A_{fp} = مساحت‌های سطح مقطع سیلاب دشت‌ها، n_{mc} = ضریب مانینگ کانال اصلی، n_{fp} = ضریب زبری سیلاب دشت‌ها.

پارمترهای مورد استفاده شده در معادله فوق به شرح زیر می‌باشد. S = شیب طولی کانال مرکب، P_{mc} = پیرامون مرطوب کانال اصلی، P_{fp} = پیرامون‌های مرطوب سیلاب



شکل ۲: انواع تقسیم‌بندی کانال مرکب، (a) تقسیم‌بندی بروش عمودی (Vertical)، (b) تقسیم‌بندی بروش قطری (Diagonal)، (c) تقسیم‌بندی بروش افقی (Horizontal) (Sahu et al., 2011).

رویکرد داده محور ماشین‌های بردار پشتیبان

- کلاس‌بندی بردار پشتیبان (SVM):


نوع خاصی از شبکه‌های عصبی هستند که بر خلاف سایر انواع شبکه‌های عصبی (مانند MLP و RBF) به جای کمینه کردن خطا، اقدام به کمینه کردن ریسک عملیاتی می‌کند. این ابزار، بسیار قدرتمند است و در زمینه‌های مختلفی چون طبقه‌بندی (SVM)، خوشه‌بندی (SVC) و مدل‌سازی (رگرسیون (SVR)) می‌تواند مورد استفاده قرار بگیرد.

ایده پایه ماشین بردار پشتیبان برای استفاده در مدل‌های خطی می‌باشد که برای پیاده‌سازی مرزهای کلاس‌بندی غیر خطی برای نقشه‌بندی غیر خطی تعدادی از داده‌ها با توجه به بردارهای ورودی در فضای ابعادی بالاتر بوجود آمده است. ساختار مدل خطی در فضای جدید می‌تواند مرزهای تصمیم‌گیری غیر خطی را در فضای اصلی به همراه داشته باشد (Wang et al., 2009). ساختار SVM بنحوی است که بهترین ابر صفحه

تقسیم‌بندی بروش افقی یک رویکرد واقع بینانه برای در نظر گرفتن واکنش بین سیلاب دشت‌ها و کانال اصلی در هنگام سیل نمی‌باشد (Sahu et al., 2011). اکثر محققین این روش را برای مطالعه و مقایسه با سایر روش‌ها در نظر نگرفتند. در روش تقسیم‌بندی قطری، نمی‌توان برای همه اشکال سطح مقطع و عمق‌های جریان این خط‌ها را بطور دقیق ترسیم کرد. ترسیم دقیق این خطوط تقسیم‌بستگی به آگاهی از خط‌های برشی صاف دارد. که این نیز بستگی به آگاهی از توزیع سرعت جریان در سه بعد دارد. در روش کانال تقسیم‌بندی شده بیشتر محققین از روش خطوط تقسیم‌بندی عمودی برای برآورد دبی کانال مرکب استفاده می‌کنند. این تقسیم‌بندی‌ها از روی نقاط ساحل رودخانه انجام می‌شود. این خطوط با تغییر پیرامون مرطوب و تقسیم سطح مقطع، به نوعی در صد شامل شدن زیر تقسیم‌بندی‌ها از واکنش بین سیلاب دشت‌ها و کانال اصلی هستند.

$$L_{\varepsilon}(d, y) = 0$$

اولین جمله از معادله ۳ بعنوان خطای تجربی شناخته می‌شود. که با توجه به معادله ۴ محاسبه خواهد شد. $L_{\varepsilon}(d, y)$ تابع کاهش شدت اِپسِیلن نامیده می‌شود. جمله دوم معادله ۳ بعنوان اندازه م سطح بودن عملکرد استفاده می‌شود. بعنوان ضریب تنظیم و تعیین کنند بین ریسک تجربی و ترم اصلاح شده است. با توجه به شکل ۴ و دو پارامتر ξ و ξ^* می‌توان با استفاده از مقدار اِپسِیلن وارد شده در شروع کار و اندازه لوله آن کمترین حاشیه نرم با توجه به بردارهای پشتیبان موجود در فضا برای تصحیح خطای وجود آمده بین داده‌های نگاشته شده را ایجاد کرد.



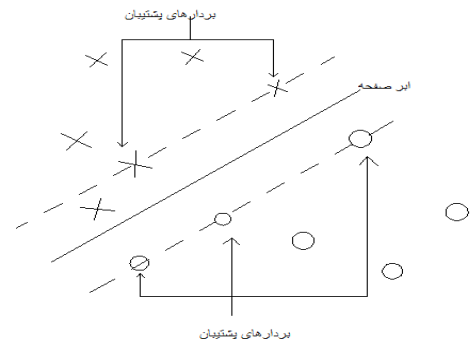
شکل ۴ تنظیمات کمترین حاشیه نرم برای SVM خطی و تابع کاهش شدت اِپسِیلن (Wang et al., 2009).

با توجه به دو پارامتر مثبت ξ و ξ^* برای بهینه سازی این مسئله محدود و پیدا کردن بهینه‌ترین فاصله داده‌ها از ابر صفحه باید از فرم معادله لاگرانژی اولیه بشرح زیر استفاده کنیم.

$$L = \frac{1}{2} \|\omega\|^2 + c \left(\sum_i (\xi_i + \xi_i^*) \right) - \sum_i \alpha_i [w_i \phi(x_i) + b - d_i + \varepsilon + \xi_i] \quad (5)$$

$$- \sum_i \alpha_i^* [d_i - w_i \phi(x_i) - b + \varepsilon + \xi_i^*] - \sum_i (\beta_i \xi_i + \beta_i^* \xi_i^*)$$

برای جداسازی داده‌ها از یکدیگر را انتخاب می‌کند. ابر صفحه انتخابی طوری می‌باشد که با توجه به دقیق‌ترین آموزش بی‌شترین فاصله را از هر داده داشته باشد. نقاط آموزش دیده که نزدیکتر از همه به ابر صفحه بهینه می‌باشند، بردارهای پشتیبان نامیده می‌شوند. شکل ۳ تصویری از بردارهای پشتیبان و ابر صفحه انتخابی بین داده‌های نگاشته شده در فضا را نشان می‌دهد.



شکل ۳ بردارهای پشتیبان و ابر صفحه انتخابی برای تفکیک داده‌های نگاشته شده در فضا (Wang et al., 2009).

در این شکل مشخصه 0 داده‌های مثبت و مشخصه X داده‌های منفی می‌باشد. معادله ۲ تابع رگرسیون ما شین بردار پشتیبان را نمایش می‌دهد.

$$y = f(x) = w_i \phi_i(x) + b \quad (2)$$

$\phi_i(x)$ تابع کرنل و w_i بردار ضرایب و b ثابت این معادله هستند. این ضرایب با استفاده از کمینه کردن تابع خطای تنظیم شده بدست می‌آید. معادلات زیر این تابع ریسک را نشان می‌دهد (Vapnik 1998).

$$r(c) = c \frac{1}{N} \sum_{i=1}^N L_{\varepsilon}(d_i, y_i) + \frac{1}{2} \|\omega\|^2 \quad (3)$$

$$L_{\varepsilon}(d, y) = |d - y| - \varepsilon \quad \text{if } |d - y| \geq \varepsilon \quad (4)$$

$$k(x_i, x_j) = (x_i \cdot x_j + 1)^n$$


$$k(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / 2\delta^2)$$

• رویکرد داده محور رگرسیون بردار پشتیبان (SVR)

در مبحث رگرسیون بردار پشتیبان، تابع تصمیم همانند معادله ۲ می باشد.

$$f(w, b) = w \cdot \phi(x) + b \quad (10)$$

شکل ۵ مفهوم SVR و نحوی قرار گیری بردارهای پشتیبان و طرز تخصیص خطاها توسط اپسیلن تیوب (ε-tube) را نمایش می دهد (Yu et al., 2009).



شکل ۵ مفهوم رگرسیون بردار پشتیبان، ایجاد صفحه بهینه رگرسیونی در بین داده‌ها در فضا و تصحیح خطای مجاز آن (Yu et al., 2009).

بطور مشابه، مسئله رگرسیون غیر خطی را می توان بصورت همان مسئله بهینه سازی مطرح کرد. با استفاده از معادله لاگرانژ می توان خطای معادله ۱۳ را بصورت زیر بهینه کنیم (Yu et al., 2009).

در معادله ۵ مینیم سازی در جهت این پارامترهای $\alpha_i, \alpha_i^*, b, \xi, \xi^*$ می باشد. و ماکزیمم سازی در جهت این پارامترها $\alpha_i, \alpha_i^*, \beta_i, \beta_i^*$ انجام می شود. در نهایت با استفاده از شرایط کاروش کوهن تا کر از معادله ۵ رگرسیون گرفته شده است. که در آخر به معادله ۶ یا همان معادله لاگرانژ دوگانه منتهی خواهد شد.

$$v(\alpha_i, \alpha_i^*) = \sum_{i=1}^N d_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) \quad (6)$$

$$- \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) k(x_i, x_j)$$

اگر از معادله $\sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0$ و شرط

$\alpha_i, \alpha_i^* \in [0, c]$ استفاده کنیم، می توان ضرایب

لاگرانژ α_i, α_i^* را محاسبه نمود. در نهایت تابع رگرسیونی ابر صفحه بصورت زیر می باشد.

$$f(x, \alpha, \alpha^*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) k(x, x_i) + b \quad (7)$$

پارامتر $k(x, x_i)$ بعنوان تابع هسته نامیده می شود. مقدار این هسته از دو تا بردار x_i و x_j در فضای ابعادی $\phi(x_i)$ و $\phi(x_j)$ بدست می آید. پس می توان اساس توابع هسته را با معادله زیر توصیف کرد.

$$k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (8)$$

توابع هسته مورد استفاده در ماشین بردار پشتیبان بصورت زیر هستند: ۱- تابع کرنل خطی (Linear kernel) ۲- تابع کرنل چند جمله ای (Polynomial kernel) ۳- تابع کرنل گوسی یا کرنل شعاعی (RBF kernel). این توابع بترتیب در سری معادلات ۹ مشخص هستند.

$$k(x_i, x_j) = x_i^T x_j \quad (9)$$

با توجه به توضیحات فوق رویکرد ماشین بردار پشتیبان هم در مبحث کلاس بندی و هم رگرسیونی عمل می‌کند. و هر دو این روش‌ها قدرت پیش بینی دارند. هم می‌توان با کلاس بندی کردن داده‌ها و هم می‌توان با رگرسیون گرفتن از آن‌ها و ایجاد شبکه آموزش دیده، برای داده‌های جدید پیش بینی را انجام داد.

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (ANN) برای پیش‌بینی محاسبات هیدرولوژی توجه بسیاری از محققین را به خود جلب کرده است (Unal et al., 2011). شبکه عصبی شامل لایه‌های ورودی، مخفی و خروجی است که توسط عناصر پردازشی به نام نرون به یکدیگر متصل می‌شوند. نرون‌ها در لایه‌های شبکه توسط وزن‌های سیناپسی متصل می‌شوند و الگوریتم یادگیری شبکه عصبی وزن‌هایش را به منظور نگاشت رابطه ورودی/خروجی به‌روز می‌کند. مجموع ورودی‌های وزن‌دار شده پردازش می‌شوند و به تابع فعال‌سازی که خروجی را تولید می‌کند، اعمال می‌شوند. وزن‌ها و بایاس‌های شبکه برای کاهش خطا بین خروجی تولید شده شبکه و خروجی موردنظر تنظیم می‌شوند. بیان ساده ریاضی از نرون به شرح زیر است. خروجی نرون را می‌توان به صورت زیر محاسبه نمود.

$$A_i = g\left(\sum_{j=0}^n W_{ij} * a_j\right) \quad (14)$$

شبکه عصبی تک‌لایه توانایی یادگیری رابطه پیچیده بین ورودی و خروجی را ندارد ولی «شبکه عصبی پرسپترون چند لایه» این توانایی را دارد. شبکه عصبی چند لایه یک یا بیش از یک لایه مخفی بین لایه‌های ورودی و خروجی شبکه دارد. این ساختار شبکه با انواع توابع فعال‌سازی مانند؛ تابع خطی، تابع پله، تابع لگستیک، مماس-هذلولی و تابع سیگموئید... توانایی بهتری برای یادگیری الگوی ورودی و تولید خروجی بهتر نسبت به شبکه عصبی

$$\frac{1}{2} w^2 + c \sum_{i=1}^L (\xi_i + \xi_i^*) \quad (11)$$

$$y_i - (w \cdot \phi(x_i) + b) \leq \varepsilon + \xi_i$$

$$(w \cdot \phi(x_i) + b) - y_i \leq \varepsilon + \xi_i^*$$

$$\xi_i, \xi_i^* \geq 0, i = 1, 2, \dots, L$$

min

$$w, b, \xi, \xi^*$$

subject - to

شکل دوگانه غیر خطی SVR را می‌توان بصورت زیر نمایش داد.

$$\frac{1}{2} \sum_{i,j=1}^L (\underline{a}_i - \overline{a}_i)(\underline{a}_j - \overline{a}_j) \langle \phi(x_i), \phi(x_j) \rangle + \varepsilon \sum_{i=1}^L (\underline{a}_i + \overline{a}_i) - \sum_{i=1}^L y_i (\underline{a}_i - \overline{a}_i) \quad (12)$$

$$\sum_{i=1}^L (\underline{a}_i - \overline{a}_i) = 0$$

$$0 \leq \underline{a}_i \leq c, i = 1, 2, \dots, n$$

$$0 \leq \overline{a}_i \leq c, i = 1, 2, \dots, n$$

min

$$\underline{a}_i, \overline{a}_i$$

subject - to

با استفاده از تابع غیر خطی $\phi(x_i)$ می‌توان در فضای ابعادی اندازه و مقدار غیر خطی $\phi(x_i), \phi(x_j)$ را محاسبه نمود. برای محاسبات فضای ورودی با استفاده از توابع هسته مختلف، محاسبات مربوط به بهینه‌سازی خطا انجام شده و این محاسبات درون فضای ورودی انجام می‌شود. در نهایت تابع هسته، بعنوان تابع تصمیم‌گیری رگرسیون بردار پشتیبان غیرخطی را می‌توان بصورت زیر نمایش داد (Yu et al., 2009).

$$f(x_i) = \sum_{k=1}^L (-\underline{a}_k + \overline{a}_k) k(x_i, x_k) + b \quad (13)$$

پارامتر $k(x, x_i)$ بعنوان تابع هسته می‌باشد. که در مبحث قبلی در کلاس بندی انواع این توابع بیان شده است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_m - Q_o)^2}{n}} \quad (15)$$

- میانگین درصد خطای مطلق (MAPE): هر اندازه این پارامتر کمتر باشد یعنی نزدیکی بهتری بین داده‌های واقعی و پیش بینی شده وجود دارد.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Q_m - Q_o}{Q_o} \right| \quad (16)$$

- ضریب کارائی مدل ناش ساتکلیف (NS): هر اندازه این پارامتر به مقدار یک نزدیک باشد، یعنی روش انتخابی برای مدل کردن این نوع داده‌ها مناسب‌تر می‌باشد. اگر مقدار این پارامتر کمتر از صفر شد نباید از روش انتخابی برای مدلسازی داده‌ها استفاده کرد.

$$NS = 1 - \frac{\sum_{i=1}^n (Q_m - Q_o)^2}{\sum_{i=1}^n (Q_o - Q_{average})^2} \quad (17)$$

در روابط بالا Q_m مقدار دبی محاسباتی می باشد که از خروجی مدل انتخابی بدست می‌آید. و Q_o مقدار دبی واقعی یا مشاهداتی می‌باشد که در آزمایشگاه اندازه‌گیری شده است.

بحث و نتایج


جدول ۲ نتایج پارامترهای ارزیابی دقت پیش بینی دبی بروش تجربی کانال تقسیم شده را نمایش می‌دهد.

جدول ۲ نتایج پارامترهای ارزیابی دقت پیش بینی دبی به روش کانال تقسیم شده

NS	(%)MAPE	RMSE($\frac{m^3}{s}$)	R^2
۰/۶۶۷۷	۱۰/۲۳۸	۰/۱۴۷۸	۰/۷۹۳۸

در ارائه نتایج در رویکردهای ماشین بردار پشتیبان، تابع چندجمله‌ای از درجه دوم را بصورت polynomial-

تک‌لایه دارد (Sahu et al., 2011). شکل ۶ ساختار شبکه عصبی مصنوعی چند لایه را نمایش می‌دهد.



شکل ۶ ساختار شبکه عصبی مصنوعی چندلایه برای پیش بینی دبی کانال مرکب (Sahu et al., 2011)

در این تحقیق از شبکه عصبی با ساختار چندلایه و تابع فعال‌سازی سیگموئید چند قطبی استفاده شده است. چرا که در ارائه نتایج و پیش بینی دقیق تر از دیگر ساختارها و توابع عمل می‌کند (Sahu et al., 2011).

پیاده سازی و اجرای مدل

ضرایب ارزیابی مدل‌های مورد استفاده

برای آزمون مدل‌های ذکر شده با استفاده از داده‌های جمع آوری شده از پارامترهای زیر استفاده می‌شود. نتایج این پارامترها مشخص می‌کند که مدل مورد استفاده تا چه اندازه در پیش بینی دبی موفق خواهد بود.

- ضریب تعیین (R^2): همبستگی داده‌های پیش بینی شده را با داده‌های فیزیکی نشان می‌دهد. هرچه مقدار این ضریب بیشتر باشد مدل بهتر ارزیابی می‌شود.
- ریشه میانگین مربع خطا (RMSE): هر اندازه این پارامتر کمتر باشد یعنی فاصله بین داده‌های واقعی و پیش بینی شده کم می‌باشد. و مدل بهتر ارزیابی می‌شود.

square و تابع چند جمله‌ای از درجه سوم را بصورت polynomial-cube نشان داده شده است

در رویکرد ماشین بردار پشتیبان در قسمت کلاس بندی و رگرسیون چهار مرتبه مدل سازی صورت گرفته است. برای ارائه نتایج، از کرنل‌های یکسان در مراحل مختلف مدل سازی میانگین گرفته شده است. جدول ۳ نتایج نهایی مدل سازی داده‌ها در رویکرد ماشین بردار پشتیبان (کلاس بندی) را نمایش می‌دهد.

جدول ۳ نتایج نهایی مدل سازی داده‌ها در SVM پس از چهار مرتبه مدل سازی و میانگین گرفتن از مدل های یکسان

جدول ۴ نتایج نهایی مدل سازی داده‌ها در SVR پس از چهار مرتبه مدل سازی و میانگین گرفتن از مدل های یکسان

	NS	MAPE (%)	RMSE($\frac{m^3}{s}$)	R^2
Linear	۷۸۷۴ ۰/	۳۴/۲۶	۰/۱۲۰۵	۸۱۶ ۰/۱
Polynomial-square	۸۹۸۰ ۰/۷۵	۲۳/۸۹	۰/۰۸۴۳۵	۹۲۸ ۰/۸
Polynomial-cube	-۰/۲۷	۴۸/۱۹	۰/۲۳۴۴	۷۵۶ ۰/
RBF	۸۲۲۱ ۰/	۳۰/۰۹	۰/۱۱۲۱	۸۴۳ ۰/۷

پس از مقایسه کرنل‌های مختلف در SVR می‌توان نتیجه گرفت که کرنل چند جمله‌ای از درجه دوم در این تکنیک در تمامی پارامترهای ارزیابی مدل از دیگر کرنل‌های مورد استفاده در پیش بینی دبی برتر می‌باشد.

جدول ۵ نتایج نهایی مدل سازی داده‌ها توسط تکنیک شبکه عصبی مصنوعی را نمایش می‌دهد. داده‌ها فیزیکی چهار مرتبه توسط این تکنیک مدل سازی شده‌اند. این جدول میانگین مراحل مختلف مدل سازی توسط این تکنیک را نمایش می‌دهد.

جدول ۵ نتیجه نهایی چهار مرتبه مدل سازی داده‌ها توسط شبکه عصبی مصنوعی و میانگین گرفتن از نتایج آنها

NS	(%)MAPE	RMSE($\frac{m^3}{s}$)	R^2
۰/۷۹۷۰۳	۵۱/۸۴۴۳	۰/۱۰۳۶۸	۰/۸۷۱۷۶

جدول ۶ مقایسه نتایج رویکرد های داده محور (برترین کرنل های مورد استفاده در دو رویکرد ماشین بردار پشتیبان مورد استفاده در این جدول قرار دارند) و روش تجربی کانال تقسیم شده در برآورد دبی کانال مرکب را نمایش می‌دهد. در این جدول درصد برتری نسبی RMSE نسبت به شبکه عصبی سنجیده شده است.


	NS	MAPE (%)	RMSE ($\frac{m^3}{s}$)	R^2
Linear	۰/۸۶۷۶	۲۴/۳۳	۰/۰۹۱۳۸	۱/۸۸۸۶ ۰/
Polynomial-square	۰/۸۴۹۱	۲۴/۸۵	۰/۰۱۰۰۲	۱/۸۸۶۸ ۰/
Polynomial-cube	۰/۸۴۵۴	۲۹/۵۴	۰/۰۱۰۱۸	۱/۸۸۶۸ ۰/
RBF	۰/۷۷۸۹	۳۶/۸۷	۰/۱۲۳۱۵	۱/۸۲۹۱ ۰/

از نتایج کرنل‌های مختلف مورد استفاده در SVM می‌توان نتیجه گرفت که کرنل خطی در رویکرد ماشین بردار پشتیبان در قسمت کلاس بندی در پیش بینی دبی در مقایسه با دیگر کرنل‌ها از موفقیت بیشتری برخوردار است.


جدول ۶ مقایسه نهایی روش تجربی کانال تقسیم شده و رویکردهای داده محور مورد استفاده در برآورد دبی کانال مرکب

RMSE نسبی	NS	(%)MAPE	RMSE($\frac{m^3}{s}$)	R^2	
-۴۲/۵۵	۰/۶۶۷۷	۱۰۲/۳۸	۰/۱۴۷۸	۰/۷۹۳۸	روش کانال تقسیم شده بر روش تقسیمات عمودی (DCM)
۱۱/۸۶	۰/۸۶۷۶	۲۴/۳۳	۰/۰۹۱۳۸	۰/۸۸۸۶	روش ماشین بردار پشتیبان (SVM)
۱۸/۶۴۴	۰/۸۹۸۰۷۵	۲۳/۸۹	۰/۰۸۴۳۵	۰/۹۲۸۸	روش رگرسیون بردار پشتیبان (SVR)
-	۰/۷۹۷۰۳	۵۱/۸۴۴۳	۰/۱۰۳۶۸	۰/۸۷۱۷۶	شبکه عصبی مصنوعی (ANN)


در میان روش‌های مورد استفاده SVR با استفاده از کرنل چند جمله‌ای از درجه دوم در مقایسه با سایر روش‌ها در برآورد دبی کانال مرکب از موفقیت بیشتری نسبی RMSE را نسبت به شبکه عصبی مصنوعی دارد. شکل ۷ نمودارهای پراکنش روش‌های جدول ۶ را نمایش می‌دهد.




(ب)



(الف)



(د)



(ج)

شکل ۷ نمودارهای پراکنش روش‌های موجود در جدول ۶. (الف) نمودار پراکنش روش کانال تقسیم شده، (ب) نمودار پراکنش ماشین بردار پشتیبان (SVM) با کرنل خطی، (ج) نمودار پراکنش ماشین بردار پشتیبان (SVR) با کرنل چند جمله‌ای از درجه دوم، (د) نمودار پراکنش شبکه عصبی مصنوعی

نتیجه گیری

RMSE نسبت به شبکه عصبی مصنوعی در پیش بینی دبی کانال مرکب موفق‌تر از دیگر روش‌ها عمل کرده است.

مطالعه و مدل‌سازی رودخانه‌ها برای آگاهی از مقدار دبی انتقال داده شده و توزیع‌های سرعت و تنش برشی از اهمیت ویژه‌ای برخوردار می‌باشند. در این تحقیق با استفاده از رویکردهای داده محور از جمله شبکه عصبی مصنوعی (ANN) و ماشین‌های بردار پشتیبان (کلاس بندی (SVM)) و رگرسیون (SVR)) و همچنین روش تجربی کانال تقسیم شده (DCM) بروش تقسیم بندی عمودی اقدام به پیش‌بینی دبی کانال مرکب شده است. پس از بررسی نتایج در هر رویکرد، نتایج برتری روش SVR را نشان داد. این روش با داشتن بیشترین مقدار R^2 و NS و کمترین مقدار RMSE و MAPE در مقایسه با سایر روش‌ها و همچنین با داشتن بیشترین درصد برتری نسبی



منابع

- Azamathulla, H.M. Zahiri, A., 2012. Flow discharge prediction in compound channels using linear genetic programming. *Journal of hydrology*, 454, pp.203-207.
- Sahu, M., Khatua, K.K. Mahapatra, S.S., 2011. A neural network approach for prediction of discharge in straight compound open channel flow. *Flow Measurement and Instrumentation*, 22(5), pp.438-446.
- Fernandes, J.N., Leal, J.B. Cardoso, A.H., 2015. Assessment of stage–discharge predictors for compound open-channels. *Flow Measurement and Instrumentation*, 45, pp.62-67.
- Noori, R., Deng, Z., Kiaghadi, A. Kachoosangi, F.T., 2015. How reliable are ANN, ANFIS, and SVM techniques for predicting longitudinal dispersion coefficient in natural rivers? *Journal of Hydraulic Engineering*, 142(1), p.04015039.
- Naik, B., Khatua, K.K., Wright, N.G. Sleight, A., 2017. Stage-discharge prediction for converging compound channels with narrow floodplains. *Journal of Irrigation and Drainage Engineering*, 143(8), p.04017017.
- Hosseini, S.M., 2004. Equations for discharge calculation in compound channels having homogeneous roughness. *Iranian Journal of Science and Technology-Transaction B: Engineering*, 28.
- Atabay, S. Knight, D.W., 2006. 1-D modelling of conveyance, boundary shear and sediment transport in overbank flow. *Journal of Hydraulic Research*, 44(6), pp.739-754.
- Mohanty, P.K. Khatua, K.K., 2014. Estimation of discharge and its distribution in compound channels. *Journal of hydrodynamics, Ser. B*, 26(1), pp.144-154.
- Knight, D.W. Demetriou, J.D., 1983. Flood plain and main channel flow interaction. *Journal of Hydraulic Engineering*, 109(8), pp.1073-1092.
- Yonesi, H.A., Omid, M.H. and Ayyoubzadeh, S.A., 2013. The hydraulics of flow in non-prismatic compound channels. *J Civil Eng Urban*, 3(6), pp.342-356.
- Unal, B., Mamak, M., Seckin, G. Cobaner, M., 2010. Comparison of an ANN approach with 1-D and 2-D methods for estimating discharge capacity of straight compound channels. *Advances in Engineering Software*, 41(2), pp.120-129.
- Wang, W.C., Chau, K.W., Cheng, C.T. Qiu, L., 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3-4), pp.294-306.
- Vapnik, V., 1998. *Statistical learning theory*. Wiley, New York.
- Yu, P.S., Chen, S.T. Chang, I.F., 2009. Real-time flood stage forecasting using support vector regression. In *Practical Hydroinformatics* (pp. 359-373). Springer, Berlin, Heidelberg.



Prediction of flow discharge in compound sections, Comparison of empirical and data driven methods

Moin Bahrapour,¹Gholamabbas Barani,²Mohammad zounemat Kerman³

Abstract:

Rivers discharge prediction in condition of situation appearance of compound channel is one of the important parameters in the flood and rivers engineering. In this investigation compound channel discharge has been predicted by using data driven methods such as artificial neural network and support vector machines (classification, regression) and also empirical method of channel divided by vertical division. For this purpose collected 150 experimental data from 6 scientific sources. This data divided to four categories twenty five percent by using k fold cross validation. In each modeling in data driven approaches, model testing performed by one group of data. After averaging of the same results in each data driven approach, the results showed the superiority of the SVR method. This method has maximum of R^2 , NS (equal to respectively 0.92875, 0.898075) and has minimum of RMSE, MAPE (equal to respectively $0.08435(\frac{m^3}{s})$, 23.89%) and also has percentage maximum of relative superiority of RMSE than artificial neural network was performed more successful than other methods in the compound channel discharge prediction.

Keywords: discharge prediction, artificial neural network, divided channel, support vector machine, compound sections, SVR

¹Msc student of water structures of Shahid Bahonar University of Kerman, Kerman, Iran. Moin.bahram@gmail.com

²Professor of civil engineering department of Shahid Bahonar University of Kerman. gab@uk.ac.ir

³Associate professor of water engineering department of Shahid Bahonar University of Kerman. zounemat@uk.ac.ir