

ЧИСЛОВІ МЕТОДИ ТА МОДЕЛІ В ГІДРОМЕТЕОРОЛОГІЇ

Б.Ф. Христюк

ORCID: 0000-0003-4290-3745

khryst@uhmi.org.ua

Л.О. Горбачова

ORCID: 0000-0003-1033-9385

gorbachova@uhmi.org.ua

УДК 556.06+556.166 (282.247.314)

DOI: [https://doi.org/10.15407/](https://doi.org/10.15407/Meteorology2025.07.071)

Meteorology2025.07.071

МОДЕЛЮВАННЯ ДОЩОВИХ ПАВОДКІВ РІЧКИ СТРИЙ ЗА ДОПОМОГОЮ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ

Український гідрометеоро-
логічний інститут Державної
служби України з надзвичайних
ситуацій та Національної
академії наук України, Київ

Своєчасне прогнозування дощових паводків на річках дозволяє уникнути негативних наслідків, які вони можуть спричиняти, руйнуючи споруди та комунікації, розташовані у їхніх руслах чи на заплавах. Це актуально для р. Стрий, оскільки в її басейні час від часу формуються катастрофічні дощові паводки. Стаття присвячена застосуванню штучної нейронної мережі (ШНМ) для моделювання дощового стоку р. Стрий біля смт. Верхнє Синьовидне за період 2005–2012 рр. Із застосуванням пакету “nnet” у RStudio (версія 2024.12.0 Build 467) розроблено модель ШНМ прямого зв'язку. Окрім цього, використано також класичну лінійну модель множинної регресії (КЛММР). Модель, заснована на ШНМ, має перевагу над КЛММР, оскільки її статистичні показники якості моделювання вищі. Так, коефіцієнт ефективності Неша-Саткліффа моделі ШНМ для навчальної вибірки склав 91,6%, а для тестової — 92,5%, що класифікує її як відмінну. Разом з цим, для КЛММР ці показники склали 81,5% та 89,4%, відповідно. Графічний аналіз також продемонстрував перевагу моделі ШНМ, оскільки саме для неї отримано краще співпадіння змодельованих і історичних значень, що підтверджують більш високі показники коефіцієнтів детермінації (0,92 ШНМ і 0,82 КЛММР для навчальної вибірки та 0,93 ШНМ і 0,89 КЛММР для тестової вибірки). Статистичні показники RMSE моделі КЛММР виявилися більшими за модель ШНМ як для навчальної (29,8 м³/с та 20,1 м³/с, відповідно), так і для тестової (25,2 м³/с та 21,1 м³/с, відповідно) вибірок. Перевага моделі ШНМ над моделлю КЛММР зумовлюється тим, що вона враховує нелінійність зв'язку “опад-стік” завдяки паралельності своєї архітектури. В Україні моделювання водного стоку річки із застосування ШНМ виконано вперше. Такий підхід може бути особливо актуальним для транскордонних річок країни, для яких існують суттєві проблеми доступності даних спостережень.

Ключові слова: моделювання дощового стоку, штучна нейронна мережа, функції активації, навчальна та тестова вибірки.

ВСТУП

Карпати — найбільш паводконебезпечних регіон України. Як і усі інші карпатські річки, річка Стрий, найбільша притока Дністра, характеризується паводковим режимом, обумовленим таненням снігового покриву весною та взимку (впродовж відлиг), а також зливами та затяжними дощами влітку та восени. Формування дощового стоку відбувається під впливом доволі складних метеорологічних чинників, що обумовлюють характер злив (інтенсивність, тривалість, площу зрошення), та ґрунтово-фізичних характеристик поверхні річкових водозборів, які визначають величину втрат на інфільтрацію, швидкість та час добігання води по схилах і в руслах (Гопченко та Гопцій, 2015).

У минулому моделюванням водного стоку р. Стрий займалися різні науковці. Зокрема, у 1983

році Сусідко М.М. створив програму “Стрий-4” для прогнозування водного стоку р. Стрий при проходженні дощових та сніго-дощових паводків. Ця програма була розроблена на основі математичної моделі формування дощового та талого стоку Гідрометцентру СРСР (Бельчиков та Корень, 1979). Програма “Стрий-4” не знайшла свого практичного використання в оперативній діяльності УкрГМЦ, оскільки вона потребувала значного масиву вихідних гідрометеорологічних даних, які не завжди були у наявності, а також мала невелику завчасність прогнозування (3–6 годин). Надалі Сусідко М.М. також розробив програму “Стрий-5”, яка була заснована на закономірностях переміщення водних мас у русловій мережі та призначалася для короткострокового прогнозування водного стоку р. Стрий із завчасністю 2–4 години (Соседко, 1976;

Соседко, 1984). Подібні моделі вимагають значно меншої кількості вихідних даних, але вони не враховують прогноз кількості опадів на найближчий період, що зменшує завчасність прогнозу водного стоку за цими моделями. Ще однією розробкою Су-сідко була програма “Дністер–10”, яка призначалася для оцінки максимальних витрат/рівнів води на гірських притоках Дністра, у тому числі, і р. Стрий під час проходження дощових паводків. Якщо до 2003 року версія цієї програми діяла на засадах фізико-статистичного підходу, то у версії 2006 року відбулося удосконалення програми шляхом використання моделі процесів формування дощового стоку “Дощ–3” (Соседко, 2000; Приймаченко, 2010). Отже, прогнози водного стоку за вище наведеними моделями мають незначну завчасність, оскільки не враховують у повній мірі прогнозів параметрів погоди, а для прогнозування паводків різного генезису використовуються різні моделі.

Моделювання водного стоку р. Стрий також виконано у праці Христюка Б.Ф та ін. (2022), у якій застосовано модуль “Rainfall-Runoff” програмного комплексу Mike 11 та прогноз параметрів погоди за мезомасштабною моделлю WRF для короткострокового прогнозування витрат води дощових паводків та створено автоматизовану систему прогнозування паводків на р. Стрий (FFS Stryi). Разом з цим, у цьому підході виникають труднощі при калібруванні модуля “Rainfall-Runoff”, які пов’язані із відсутністю спостережень за випаровуванням з поверхні водозбору.

Одним із перспективних напрямків моделювання водного стоку річок є застосування моделей, заснованих на штучних нейронних мережах (ШНМ). Розроблення детальних математичних моделей штучних нейронних мереж розпочалася ще у 40-х роках минулого століття з роботи МакКаллоха та Піттса (1943), а перша нейронна мережа була розроблена Розенблаттом (1959). Застосування штучних нейронних мереж у різних напрямках гідрології розпочалося у 90-х роках минулого століття. Зокрема, для моделювання зв’язків “опад-стік” (Minns & Hall, 1996; Shamseldin, 1997), а у подальшому — при моделюванні транспорту наносів (Tayfur, 2002), при оцінці, прогнозуванні та екстраполяції річкового стоку (Cigizoglu, 2003), при обробці даних штучного дощування (Chakravarti et al., 2015). У окремих випадках, моделі засновані на ШНМ дають кращі результати моделювання, ніж концептуальні моделі, особливо коли дані спостережень є епізодичними та нетривалими (Ghumman et al., 2011).

Принципова перевага ШНМ полягає у її здатності враховувати як лінійні, так і нелінійні зв’язки та вивчати їх безпосередньо за вихідними даними.

ШНМ — це швидкий та гнучкий підхід, який був визнаний прийнятним для моделювання різноманітних гідрологічних процесів. Однак, схожість моделей ШНМ із моделями “чорного ящика” викликає негативну реакцію у частини дослідників (Guide to Hydrological Practices, 2009).

Нейронні мережі працюють як людський мозок. Вони отримують певну інформацію, опрацьовують її приховано, а потім видають результат. Розробка моделі, заснованої на ШНМ, зазвичай полягає у визначенні її архітектури та вибору функції активації. Спочатку необхідно визначитися із кількістю шарів та розстановкою нейронів у цих шарах. Кількість нейронів у вхідному шарі відповідає кількості незалежних змінних, яку, в свою чергу, можна визначити кореляційним аналізом. При цьому, слід уникати мультиколінійності між двома або більше незалежними змінними. Кількість нейронів прихованого шару моделі визначається шляхом оптимізації, методом спроб та помилок. Функція активації визначає вихідне значення нейрона в залежності від результату зваженої суми входів та порогового значення. У моделях ШНМ, залежно від задач моделювання, використовують значний перелік функцій активації. Найвідоміші з них — східчаста, лінійна, сигмоїдна та гіперболічний тангенс (Ripley, 1996).

Метою дослідження є застосування штучної нейронної мережі для моделювання водного стоку р. Стрий біля смт. Верхнє Синьовидне у теплий період року за даними про опади та водність річки.

МАТЕРІАЛИ ТА МЕТОДИ ДОСЛІДЖЕННЯ

У дослідженні використані дані мережі спостережень Українського гідрометеорологічного центру: витрати води на гідрологічному посту р. Стрий — смт Верхнє Синьовидне та кількість опадів на метеорологічних станціях Турка, Стрий і Славське за травень-вересень 2005–2012 рр. з кроком у часі 6 годин, що відповідає частоті спостережень за опадами на цих метеорологічних станціях. Указаний період був вибраний тому, що у 2008 на р. Стрий спостерігався дощовий паводок, найвищий за останні 40 років.

Кількість опадів на метеорологічних станціях Турка, Стрий і Славське за кожний строк спостережень осереднювався за формулою:

$$P_i = \frac{P_i^T + P_i^{CT} + P_i^{CL}}{3}, \quad (1)$$

де P_i — середня кількість опадів за i -й строк спостережень; $P_i^T, P_i^{CT}, P_i^{CL}$ — кількість опадів на метеорологічних станціях Турка, Стрий та Славське за i -й строк спостережень, відповідно.

Витрати води на гідрологічному посту р. Стрий — смт. Верхнє Синьовидне визначалися за рівнями води за кривими витрат. Значення витрат води між стандартними строками спостережень (8 та 20 год) із кроком у часі 6 годин визначалися шляхом лінійної або поліноміальної інтерполяції. Слід зазначити, що при проходженні високих дощових паводків на р. Стрий, спостереження на посту р. Стрий — смт. Верхнє Синьовидне за рівнями води проводяться частіше стандартних строків, а саме о 4, 12, 16 та 24 годинах.

Попередньо значення витрат води та середньої кількості опадів були нормалізовані зважаючи на те, що вони вимірюються у різних числових діапазонах. Нормалізація змінних величин (Z-нормалізація) відбувалася за формулою:

$$X' = \frac{X_i - \bar{X}}{\sigma}, \quad (2)$$

де X' , X_i , $\bar{X}$ — нормалізоване, початкове та середнє значення змінної величини, відповідно; σ — стандартне відхилення.

Усі розрахунки були виконані у RStudio (версія 2024.12.0 Build 467) із використанням пакету “nnet” (Ripley, 1996; R Core Team, 2017). Програмний код був нами написаний мовою R. Пакет “nnet” в основному зосереджений на нейронних мережах прямого зв'язку, які є типом штучної нейронної мережі, де інформація тече в одному напрямку, від вхідного до вихідного шару. Ці мережі добре підходять для таких завдань, як класифікація та регресія. Пакет “nnet” дозволяє вказати архітектуру моделі з кількістю нейронів у кожному шарі та функцію активації.

У якості функції активації використовувалася логістична сигмоїдна функція ($f(x)$), яка має вигляд (Hornik et al., 1989):

$$f(x) = \frac{1}{1 + e^{-x}}, \quad (3)$$

де x — вихідні дані.

Передача інформації від нейронів вхідного шару до нейронів прихованого шару відбувається за правилом підсумовування зважених значень зв'язків між нейронами:

$$X_j = \sum_{i=1}^N (x_i \cdot w_{ij}), \quad (4)$$

де X_j — сумарне значення на вході j -го нейрону прихованого шару; N — кількість нейронів вхідного шару; x_i — значення, яке передається від i -го нейрону вхідного шару до j -го нейрону прихованого шару; w_{ij} — вага зв'язку, яка з'єднує нейрон i з нейроном j .

Аналогічно відбувається передача інформації від нейронів прихованого шару до нейрона вихідного шару:

$$X_k = \sum_{j=1}^N (x_j \cdot w_{jk}), \quad (5)$$

де індекси j та k відповідають індексам нейронів прихованого шару та нейрону вихідного шару, відповідно.

Результати моделювання витрат води навчальної та тестової вибірок оцінювалися за трьома статистичними показниками: коефіцієнтом ефективності моделі Неша-Саткліфа (NSE), RMSE (квадратним коренем з середньоквадратичної різниці між змодельованими і фактичними значеннями) та коефіцієнтом детермінації (R^2). Окрім цього, відбувалося графічне порівняння змодельованих та історичних значень.

Коефіцієнт ефективності моделі Неша-Саткліфа (NSE) визначався за формулою (Nash & Sutcliffe, 1970):

$$NSE = \left[1 - \frac{\sum_{i=1}^n (Y_{\phi i} - Y_{mi})^2}{\sum_{i=1}^n (Y_{\phi i} - \bar{Y}_{\phi})^2} \right] \cdot 100\%, \quad (6)$$

де $Y_{\phi i}$ та Y_{mi} — фактичні та змодельовані значення величин, відповідно; $\bar{Y}_{\phi}$ — середнє значення фактичної величини; n — кількість даних.

Моделі, які мають коефіцієнт ефективності $NSE = 100\%$ відносяться до ідеальних, більше 90% — до відмінних, $80-90\%$ — дуже добрих, $60-80\%$ — добрих, $<60\%$ — до незадовільних (Aoulmi et al., 2021).

Статистичний показник RMSE використовується для кількісної оцінки похибки між історичними та змодельованими значеннями величини, яка досліджується (Настанова з оперативної гідрології, 2012):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{\phi i} - Y_{mi})^2}{n}}, \quad (7)$$

Коефіцієнт детермінації (R^2) є мірою ступеню відповідності моделі фактичним даним. Він показує, яку долю варіації залежної змінної можна пояснити незалежною змінною або кількома змінними.

Окрім моделі, заснованої на ШНМ, були виконані також розрахунки за класичною лінійною моделлю множинної регресії (КЛММР) за тими ж вихідними даними.

РЕЗУЛЬТАТИ ТА ЇХНЕ ОБГОВОРЕННЯ

В якості вихідних даних моделі формування дощового стоку р. Стрий у теплий період року нами були використані дані про опади та водність річки. Після побудови кореляційної матриці вихідних даних встановлено, що витрати води р. Стрий — Верхнє Синьовидне (Q_t) корелюють із витратою води за попередній строк (6 годин потому) (Q_{t-6}) та се-

Таблиця 1. Кореляційна матриця вихідних даних

	Qt	Qt-6	Pt-6	Qt-12	Pt-12	Qt-18	Pt-18	Qt-24	Pt-24
Qt	1								
Qt-6	0,91	1							
Pt-6	0,41	0,25	1						
Qt-12	0,77	0,91	0,15	1					
Pt-12	0,46	0,41	0,37	0,25	1				
Qt-18	0,64	0,77	0,12	0,91	0,15	1			
Pt-18	0,44	0,46	0,16	0,41	0,37	0,25	1		
Qt-24	0,55	0,64	0,10	0,77	0,12	0,91	0,15	1	
Pt-24	0,37	0,44	0,14	0,46	0,16	0,41	0,37	0,25	1

редньою кількістю опадів, яка випала на поверхню водозбору о 6, 12, 18 та 24 години потому (P_{t-6} , P_{t-12} , P_{t-18} , P_{t-24}) (табл. 1). Витрати води за строки спостережень 12, 18 та 24 години (Q_{t-12} , Q_{t-18} , Q_{t-24}) у функціональній залежності не були враховані, оскільки їхнє врахування приводить до мультиколеніарності: коефіцієнти кореляції між Q_{t-6} та Q_{t-12} , Q_{t-12} та Q_{t-18} , Q_{t-18} та Q_{t-24} становлять 0,91. Отже, функціональна залежність має наступний вигляд:

$$Q_t = f(Q_{t-6}, P_{t-6}, P_{t-12}, P_{t-18}, P_{t-24}). \tag{8}$$

Значення Q_{t-6} , P_{t-6} , P_{t-12} , P_{t-18} та P_{t-24} стали п'ятьма нейронами вхідного шару моделі ШНМ. Кількість нейронів прихованого шару моделі визначалась шляхом оптимізації, методом спроб та помилок.

Перебір кількості нейронів відбувався в межах від 2 до 15. Найменшу середньоквадратичну похибку було отримано при трьох нейронах прихованого шару. Вихідний шар моделі складається з одного нейрона (рис. 1).

Усі наявні дані гідрометеорологічних спостережень за 2005–2012 рр. були розділені на дві рівні частини, які склали навчальну та тестову вибірки. Поділ на дві рівні частини відбувався не за календарним принципом, а випадково. Загалом, було використано значення витрат води та кількості опадів за 4888 строків спостережень.

Моделю ШНМ, отримана за даними навчальної вибірки, була застосована до тестової вибірки. Ре-




Рис. 1. Архітектура штучної нейронної мережі, яка використана у дослідженні

зультати моделювання навчальної та тестової вибірок мають гарні статистичні показники (табл. 2).

Так, коефіцієнт ефективності Неша-Саткліффа моделі ШНМ для навчальної вибірки склав 91,6%, а для тестової — 92,5%, що визначається як відмінна модель. Ці результати підтверджуються також графічним порівнянням змодельованих і історичних значень. Як для навчальної, так і для тестової вибірок отримано гарне співпадіння змодельованих та історичних значень, що підтверджується трендами і значеннями коефіцієнтів детермінації (0,92 для навчальної та 0,93 для тестової вибірок), які наближаються до одиниці (рис. 2).

Дані навчальної та тестової вибірки також були використані для розрахунків за класичною лінійною моделлю множинної регресії. Регресійне рівняння

Таблиця 2. Статистичні показники навчальної та тестової вибірок за різними моделями

Модель	Навчальна вибірка			Тестова вибірка		
	NSE, (%)	RMSE, (м³/с)	R²	NSE, (%)	RMSE, (м³/с)	R²
ШНМ	91,6	20,1	0,92	92,5	21,1	0,93
КЛММР	81,5	29,8	0,82	89,4	25,2	0,89




Рис. 2. Графіки розсіювання історичних та змодельованих ШНМ витрат води на гідрологічному посту р. Стрий — смт. Верхнє Синьовидне для навчальної (а) і тестової (б) вибірок (червона лінія — теоретичний тренд у випадку, коли історичні і змодельовані витрати води повністю співпадають; синя пунктирна лінія — тренд між історичними і змодельованими витратами)

було встановлене за навчальною вибіркою та застосоване до тестової вибірки у вигляді:

$$Q_t = -0,64 + 0,84 \cdot Q_{t-6} + 5,50 \cdot P_{t-6} + 1,70 \cdot P_{t-12} + 1,16 \cdot P_{t-18} - 1,54 \cdot P_{t-24}. \quad (9)$$

Якість результатів моделювання навчальної та тестової вибірок за моделлю КЛММР нижча у порівнянні з моделлю ШНМ (табл. 2). Так, коефіцієнт ефективності Неша-Саткліфа моделі КЛММР для навчальної вибірки склав 81,5%, а для тестової — 89,4%. Ці показники визначають модель КЛММР як дуже добру, але це гірше ніж модель ШНМ, яка відноситься до відмінних.

Графічний аналіз також демонструє погіршення результатів за моделлю КЛММР, оскільки на графіках чіткіше простежується відхилення тренду моделі КЛММР від теоретичного тренду як для навчальної, так і для тестової вибірок (рис. 3).

Це підтверджується значеннями коефіцієнтів детермінації, які склали 0,82 для навчальної і 0,89 для тестової вибірок. Ці показники також є нижчими у порівнянні з моделлю ШНМ. Окрім цього, статистичні показники RMSE моделі КЛММР виявилися більшими ніж моделі ШНМ як для навчальної (29,8 м³/с та 20,1 м³/с, відповідно), так і для тестової (25,2 м³/с та 21,1 м³/с, відповідно) вибірок.




Рис. 3. Графіки розсіювання історичних та змодельованих КЛММР витрат води на гідрологічному посту р. Стрий — смт. Верхнє Синьовидне для навчальної (а) і тестової (б) вибірок (червона лінія — теоретичний тренд у випадку, коли історичні і змодельовані витрати води повністю співпадають; синя пунктирна лінія — тренд між історичними і змодельованими витратами)

За усіма трьома статистичними параметрами (табл. 2), а також за графічним порівнянням змодельованих та фактичних значень (рис. 2 та рис. 3), модель ШНМ має перевагу над КЛММР. Така перевага обумовлена тим, що модель ШНМ враховує нелінійність зв'язку "опад-стік" завдяки паралельності своєї архітектури.

Розроблена модель ШНМ для моделювання дощових паводків на р. Стрий дозволяє отримувати хороші результати моделювання з мінімальним набором вихідної інформації, що є її перевагою. Загалом, результати цього дослідження узгоджуються з подібними дослідженнями закордонних вчених, у яких розроблялись моделі ШНМ для водозборів річок із різними умовами формування водного стоку та, у яких показано, що ШНМ можуть забезпечувати більш якісне моделювання у порівнянні з традиційними моделями (Riad et al, 2004; Ghumman et al., 2011; Mohseni & Muskula, 2023).

ВИСНОВКИ

У минулому для моделювання водного стоку р. Стрий використовувалися методики, засновані на закономірностях переміщення водних мас у русловій мережі та математичні моделі, які враховують основні гідрологічні процеси на водозборі. Разом з цим, такі підходи потребують значної кількості вихідних гідрометеорологічних даних, що ускладнює їхнє практичне застосування.

У цьому дослідженні для моделювання дощового стоку р. Стрий застосована ШНМ прямого зв'язку пакету "nnet" у RStudio (версія 2024.12.0 Build 467). У якості вихідних даних використано відомості про кількість опадів та витрати води для водозбору р. Стрий у пункті спостережень смт. Верхнє Синьовидне за період 2005–2012 рр., який містить найвищий за останні 40 років дощовий паводок 2008 року. Розроблена модель ШНМ для моделювання дощового стоку р. Стрий класифікується як відмінна згідно коефіцієнту ефективності Неша-Саткліфа, який для навчальної вибірки склав 91,6%, а для тестової — 92,5%. Такий результат підтверджуються графічним аналізом, який показав гарне співпадіння змодельованих і історичних значень, а також високими значеннями коефіцієнтів детермінації (0,92 для навчальної та 0,93 для тестової вибірок). Виявилось, що модель ШНМ має перевагу над КЛММР, оскільки вона має вищі статистичні показники якості моделювання. Це обумовлюється тим, що модель ШНМ враховує нелінійність зв'язку "опад-стік" завдяки паралельності своєї архітектури.

Описаний у статті підхід використання ШНМ для моделювання водного стоку річки застосовано в Україні вперше. Такий підхід може бути використаний і для інших річок нашої країни, і, особливо, для транскордонних, для яких існують суттєві проблеми у доступності даних спостережень.

ЛІТЕРАТУРА

- Бельчиков, В.А., & Корень, В.И. (1979). Модель формирования талого и дождевого стока для лесных водосборов. *Труды Гидрометцентра СССР*, **218**, 3–21.
- Гопченко, Є.Д., & Гопцій, М.В. (2015). Максимальний стік дощових паводків у Передкарпатті: монографія. Одеса: ТЕС.
- Настанова з оперативної гідрології (2012). Прогнози режиму вод суші. Гідрологічне забезпечення і обслуговування. Київ: ПП Верлан.
- Приймаченко, Н.В. (2010). Обґрунтування системи розрахунку характеристик паводків на гірських річках басейну Дністра на основі математичного моделювання процесів формування дощового стоку. Автореф. дис. ... канд. геогр. наук: 11.00.07. Київський національний університет ім. Тараса Шевченка, Київ.
- Соседко, М.Н. (1976). Прогноз хода стока дождевого стока на горных реках бассейна Днестра с учётом неравномерности притока. *Труды УкрНИГМИ*, **143**, 132–147.
- Соседко, М.Н. (1984). Разработать рекомендации и требования к проекту подсистемы прогнозирования паводков АСУБ Стрыя: отчет о НИР. Киев: Украинский региональный научно-исследовательский институт.
- Сусідко, М.М. (2000). Математичне моделювання процесів формування стоку як основа прогностичних систем. *Гідрологія, гідрохімія і гідроекологія*, **1**, 32–40.
- Aoulmi, Y., Marouf, N., & Amireche, M. (2021). The assessment of artificial neural network rainfall-runoff models under different input meteorological parameters. Case study: Seybouse basin, Northeast Algeria. *Journal of water and land development*, **50**(VI–IX), 38–47. <https://doi.org/10.24425/jwld.2021.138158>
- Chakravarti, A., Joshi, N., & Panjiar, H. (2015). Rainfall Runoff Analysis Using Artificial Neural Network. *Indian Journal of Science and Technology*, **8**(14), 1–7. <https://doi.org/10.17485/ijst/2015/v8i14/54370>
- Cigizoglu, H.K. (2003). Estimation, forecasting and extrapolation of river flows by artificial neural networks. *Hydrological Science Journal*, **48**(3), 349–361. <https://doi.org/10.1623/hysj.48.3.349.45288>
- Ghumman, A.R., Ghazaw, Y.M., Sohail, A.R., & Watanabe K. (2011). Runoff forecasting by artificial neural network and conventional model. *Alexandria Engineering Journal*, **50**, 345–350. <https://doi.org/10.1016/j.aej.2012.01.005>
- Guide to Hydrological Practices (2009). Management of Water Resources and Application of Hydrological Practices. Vol. II. Sixth edition. WMO-No. 168. Geneva: World Meteorological Organization.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feed-forward networks are universal approximators. *Neural Networks*, **2**(5), 359–366. [https://doi.org/10.1016/0893-6080-\(89\)90020-8](https://doi.org/10.1016/0893-6080-(89)90020-8)
- Khrystiuk, B., Gorbachova, L., & Shpyg, V. (2022). Verification of the automated flood forecasting system on the Striy River. *Acta Hydrologica Slovaca*, **23**(2), 234–240. <https://doi.org/10.31577/ahs-2022-0023.02.0026>

- McCulloch, W.S., & Pitts W. (1943). A Logical Calculus of the Ideas Imminent in Neural Activity. *Bulletin of Mathematical Biophysics*, **5**, 115–133. <https://doi.org/10.1007/BF02478259>
- Minns, A.W., & Hall, M.J. (1996). Artificial neural networks as rainfall-runoff models. *Hydrological Science Journal*, **41**(3), 399–417. <https://doi.org/10.1080/02626669609491511>
- Mohseni, U.; Muskula, S.B. (2023). Rainfall-Runoff Modeling Using Artificial Neural Network—A Case Study of Purna Sub-Catchment of Upper Tapi Basin, India. *Environmental Sciences Proceedings*, **25**, 1. <https://doi.org/10.3390/ECWS-7-14232>
- Nash, J.E., & Sutcliffe, J.V. (1970). River flow forecasting through conceptual models, part1 — a discussion of principles. *Journal of Hydrology*, **10**(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- R Core Team (2017). A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria. Available at: <https://www.r-project.org>
- Riad, S., Mania, J., Bouchaou, L., Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, **40**(7–8), 839–846. <https://doi.org/10.1016/j.mcm.2004.10.012>
- Ripley, B.D. (1996). Pattern Recognition and Neural Networks. Cambridge University Press.
- Rosenblatt, R. (1959). Principles of Neurodynamics. New York: Spartan Books.
- Shamseldin, A.Y. (1997). Application of a neural network technique to rainfall-runoff modeling. *Journal of Hydrology*, **199**(3–4), 272–294. [http://dx.doi.org/10.1016/S0022-1694\(96\)03330-6](http://dx.doi.org/10.1016/S0022-1694(96)03330-6)
- Tayfur, G. (2002). Artificial neural networks for sheet sediment transport. *Hydrological Science Journal*, **47**(6), 879–892. <https://doi.org/10.1080/02626660209492997>
- Aoulmi, Y., Marouf, N., & Amireche, M. (2021). The assessment of artificial neural network rainfall-runoff models under different input meteorological parameters. Case study: Seybouse basin, Northeast Algeria. *Journal of water and land development*, **50**(VI–IX), 38–47. <https://doi.org/10.24425/jwld.2021.138158>
- Belchikov, V.A., & Koren, V.I. (1979). Model of the formation of melting and rain runoff for forest catchments. *Proceedings of the Hydrometeorological Center of the USSR*, **218**, 3–21. [in Russian]
- Chakravarti, A., Joshi, N., & Panjiar, H. (2015). Rainfall Runoff Analysis Using Artificial Neural Network. *Indian Journal of Science and Technology*, **8**(14), 1–7. <https://doi.org/10.17485/ijst/2015/v8i14/54370>
- Cigizoglu, H.K. (2003). Estimation, forecasting and extrapolation of river flows by artificial neural networks. *Hydrological Science Journal*, **48**(3), 349–361. <https://doi.org/10.1623/hysj.48.3.349.45288>
- Ghumman, A.R., Ghazaw, Y.M., Sohail, A.R., & Watanabe K. (2011). Runoff forecasting by artificial neural network and conventional model. *Alexandria Engineering Journal*, **50**, 345–350. <https://doi.org/10.1016/j.aej.2012.01.005>
- Gopchenko, E.D., & Goptsiy, M.V. (2015). Maximum runoff of rain floods in the Carpathian Mountains: monograph. Odesa: TES. [in Ukrainian]
- Guide to Hydrological Practices (2009). Management of Water Resources and Application of Hydrological Practices. Vol. II. Sixth edition. WMO-No. 168. Geneva: World Meteorological Organization.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feed-forward networks are universal approximators. *Neural Networks*, **2**(5), 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)
- Khrystiuk, B., Gorbachova, L., & Shpyg, V. (2022). Verification of the automated flood forecasting system on the Stryi River. *Acta Hydrologica Slovaca*, **23**(2), 234–240. <https://doi.org/10.31577/ahs-2022-0023.02.0026>
- McCulloch, W.S., & Pitts W. (1943). A Logical Calculus of the Ideas Imminent in Neural Activity. *Bulletin of Mathematical Biophysics*, **5**, 115–133. <https://doi.org/10.1007/BF02478259>
- Minns, A.W., & Hall, M.J. (1996). Artificial neural networks as rainfall-runoff models. *Hydrological Science Journal*, **41**(3), 399–417. <https://doi.org/10.1080/02626669609491511>
- Mohseni, U.; Muskula, S.B. (2023). Rainfall-Runoff Modeling Using Artificial Neural Network—A Case Study of Purna Sub-Catchment of Upper Tapi Basin, India. *Environmental Sciences Proceedings*, **25**, 1. <https://doi.org/10.3390/ECWS-7-14232>
- Nash, J.E., & Sutcliffe, J.V. (1970). River flow forecasting through conceptual models, part1 — a discussion of principles. *Journal of Hydrology*, **10**(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Operational Hydrology Manual (2012). Forecasts of the Land Water Regime. Hydrological Support and Maintenance. Kyiv: Verlan Publishing House. [in Ukrainian]
- Pryimachenko, N.V. (2010). Substantiation of the system for calculating flood characteristics on mountain rivers of the Dniester basin based on mathematical modeling of rain runoff formation processes. Avtoref. dys. ... kand. geogr. nauk: 11.00.07. Taras Shevchenko National University of Kyiv. [in Ukrainian]
- R Core Team (2017). A language and environment for statistical computing. R Foundation for Statistical Computing. Vienna, Austria. Available at: <https://www.r-project.org>
- Riad, S., Mania, J., Bouchaou, L., Najjar, Y. (2004). Rainfall-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, **40**(7–8), 839–846. <https://doi.org/10.1016/j.mcm.2004.10.012>
- Ripley, B.D. (1996). Pattern Recognition and Neural Networks. Cambridge University Press.
- Rosenblatt, R. (1959). Principles of Neurodynamics. New York: Spartan Books.
- Shamseldin, A.Y. (1997). Application of a neural network technique to rainfall-runoff modeling. *Journal of Hydrology*, **199**(3–4), 272–294. [http://dx.doi.org/10.1016/S0022-1694\(96\)03330-6](http://dx.doi.org/10.1016/S0022-1694(96)03330-6)
- Sosedko, M.N. (1976). Forecast of the course of rain runoff on the mountain rivers of the Dniester basin, taking into account the unevenness of the inflow. *Proceedings of UkrNIHMA*, **143**, 132–147. [in Russian]
- Sosedko, M.N. (1984). Develop recommendations and requirements for the flood forecasting subsystem project of ASUB Stryi: report on research. Kyiv: Ukrainian Regional Research Institute. [in Russian]
- Susidko, M.M. (2000). Mathematical modeling of runoff formation processes as a basis of forecasting systems. *Hydrology, Hydrochemistry and Hydroecology*, **1**, 32–40. [in Ukrainian]
- Tayfur, G. (2002). Artificial neural networks for sheet sediment transport. *Hydrological Science Journal*, **47**(6), 879–892. <https://doi.org/10.1080/02626660209492997>

Borys Khrystiuk

ORCID: 0000-0003-4290-3745

khryst@uhmi.org.ua

Liudmyla Gorbachova

ORCID: 0000-0003-1033-9385

gorbachova@uhmi.org.ua

*Ukrainian Hydrometeorological Institute
of the State Emergency Service of Ukraine and
the National Academy of Sciences of Ukraine, Kyiv*

SIMULATION OF RAIN FLOODS OF THE STRYI RIVER BY AN ARTIFICIAL NEURAL NETWORK

Timely forecasting of rain floods on rivers allows you to avoid the negative consequences that they can cause by destroying structures and communications located in their channels or on floodplains. It is relevant for the Stryi River, as catastrophic rain floods occur in its basin from time to time. The article is devoted to the use of an artificial neural network (ANN) for modeling the rain runoff of the Stryi River near the Verkhnie Synyovdne village for the period 2005–2012. Using the “nnet” package in RStudio (version 2024.12.0 Build 467), a direct-connection ANN model was developed. In addition, the classical linear multiple

regression model (CLMRM) was also used. The model based on ANN has an advantage over the CLMRM, as its statistical indicators of modeling quality are higher. Thus, the Nash-Sutcliffe efficiency coefficient of the ANN model for the training sample was 91.6%, and for the test sample was 92.5%, which classifies it as excellent. However, for CLMRM these indicators were 81.5% and 89.4%, respectively. Graphical analysis also demonstrated the advantage of the ANN model, since it was for it that a better match between the simulated and historical values was obtained, which is confirmed by higher of determination coefficients (0.92 ANN and 0.82 CLMRM for the training sample and 0.93 ANN and 0.89 CLMRM for the test sample). The statistic indicators RMSE of the CLMRM model turned out to be greater than the ANN model for both the training (29.8 m³/s and 20.1 m³/s) and test (25.2 m³/s and 21.1 m³/s) samples. The advantage of the ANN model over the CLMRM model is that it takes into account the nonlinearity of “rainfall-runoff” relationship due to the parallelism of its architecture. In Ukraine, river flow modeling by ANNs was carried out for the first time. This approach may be particularly relevant for transboundary rivers of the country, for which there are significant problems with the availability of observation data.

Keywords: simulation of rain flow, artificial neural network, activation functions, training and test samples

