

НАУЧНАЯ СТАТЬЯ / RESEARCH PAPER

УДК 556.535.3

DOI: 10.22227/2305-5502.2022.4.7

Эффективность программы MIKE-NAM для моделирования стока с использованием моделей искусственного интеллекта

Алаа Слейман, Дмитрий Вячеславович Козлов

*Национальный исследовательский Московский государственный строительный университет
(НИУ МГСУ); г. Москва, Россия*

АННОТАЦИЯ

Введение. Возможность моделирования речного стока является важным шагом в процессе гидрологического моделирования и, следовательно, в изучении водного баланса. Цель исследования — проверка способности и надежности программы MIKE 11 NAM в моделировании стока в верхней части бассейна р. Оронт в Сирии с использованием моделей искусственного интеллекта.

Материалы и методы. Использованы модели искусственных нейронных сетей (ИНС) и модели нечеткого логического вывода (НЛВ), которые сравнивались друг с другом для определения лучшей модели с целью «заполнения пробелов» в сведениях о поверхностном стоке на станциях наблюдения Аль-Джавадия и Аль-Амири. Полученные выходные данные применены в процессе моделирования с помощью программы MIKE 11 NAM.

Результаты. Определили высокую эффективность моделей искусственного интеллекта как нейронных сетей, так и модели НЛВ, с некоторым предпочтением нейронных сетей. Использование полученных результатов в качестве входных данных для моделирования стока в программе MIKE показало, что существуют большие различия между наблюдаемыми и смоделированными значениями, по-видимому, из-за ограниченности исходной информации на исследуемой территории речного бассейна.

Выводы. Рекомендовано продолжить исследование эффективности математических моделей формирования стока в условиях недостаточности и ограниченности исходной информации с целью поиска наилучшего способа решения этой проблемы.

КЛЮЧЕВЫЕ СЛОВА: речной сток, MIKE 11 NAM, искусственный интеллект, искусственные нейронные сети, модель нечеткого логического вывода, водный баланс, моделирование

ДЛЯ ЦИТИРОВАНИЯ: Слейман А., Козлов Д.В. Эффективность программы MIKE-NAM для моделирования стока с использованием моделей искусственного интеллекта // Строительство: наука и образование. 2022. Т. 12. Вып. 4. Ст. 7. URL: <http://nsj-journal.ru>. DOI: 10.22227/2305-5502.2022.4.7

Автор, ответственный за переписку: Алаа Слейман, alaa-slieman@hotmail.com.

Efficiency of MIKE-NAM model for runoff modeling using artificial intelligence

Alaa Slieman, Dmitry V. Kozlov

*Moscow State University of Civil Engineering (National Research University) (MGSU);
Moscow, Russian Federation*

ABSTRACT

Introduction. The ability of runoff modeling is an essential step in the hydrologic modeling process and therefore water balance studies, therefore, this study aims to verify the ability and reliability of the MIKE 11NAM program in modeling runoff, in the upper basin of Orontes River in Syria, with the use of artificial intelligence models to fill the gaps in runoff time series.

Materials and methods. In this study, models of artificial neural networks and fuzzy inference models were used and they were compared with each other to determine the best model in order to fill the gaps in the surface runoff data at Al-Jawadiyah and Al-Amiri stations. Then the results were used in the modeling process using the MIKE 11 NAM program.

Results. The results showed a high reliability of artificial intelligence models, whether neural networks or fuzzy inference models, with a relative preference for neural networks, and after using these results within the data required for modeling in the Mike program, it was found that there are large differences between the observed and simulated values due to the lack of existing data on the study area.

Conclusions. This study recommends to continue research on the issue of hydrological modeling in case of lack of data and to compare between different models to find the best way to solve this problem.

KEYWORDS: runoff, MIKE 11 NAM, artificial intelligence, artificial neural networks, fuzzy inference system, water balance, modeling

FOR CITATION: Slieman A., Kozlov D.V. Efficiency of MIKE-NAM model for runoff modeling using artificial intelligence. *Stroitel'stvo: nauka i obrazovanie* [Construction: Science and Education]. 2022; 12(4):7. URL: <http://nsso-journal.ru>. DOI: 10.22227/2305-5502.2022.4.7

Corresponding author: Alaa Slieman, alaa-slieman@hotmail.com.

ВВЕДЕНИЕ

Возможность моделирования стока является важным этапом процесса гидрологического моделирования и, соответственно, исследования водного баланса и всех научных работ, связанных с водными ресурсами, что способствует интеграции управления водными ресурсами в рассматриваемой области.

В последнее время модели искусственного интеллекта пользуются большим вниманием. Проведено множество исследований на предмет их применимости к области водных ресурсов и гидрологии. Некоторые авторы изучили возможность использования искусственных нейронных сетей (ИНС) для прогнозирования и оценки величины поверхностного стока и получили надежные результаты [1–6]. Другие исследователи применили модели нечетких выводов для моделирования и оценки поверхностного стока [7, 8], также было проведено сравнение моделей ИНС и нечетких выводов для моделирования поверхностного стока, в результате которого получены сопоставимые результаты [9, 10]. К.Х. Вонг и А. Алтункайнар (2012) сравнили модель управления ливневыми водами (SWMM) и модели нечеткого вывода, результаты показали превосходство моделей нечеткого вывода [11].

Кроме того, ученые заинтересованы в использовании гидрологических моделей типа HEC HMS и Arc SWAT [12–14]; ряд исследований в области гидрологического моделирования выполнялись с помощью модели Mike, этим вопросом занимался Кок и его коллеги (2019). Они задействовали программное обеспечение MIKE URBAN для оценки эффективности программы Active, Beautiful and Clean (ABC) с целью управления ливневыми стоками, полученные результаты показали достаточную сходимость с требуемыми значениями [15]. Ангсом и Д.В. Козлов (2020) также использовали программу MIKE 11 NAM для оценки применимости данных повторного климатического анализа при моделировании дождевого стока в малоизученном бассейне реки в Эритрее, результаты продемонстрировали завышение количества осадков [16]. Другие авторы указали на способность модели Mike моделировать поверхностный сток, а также подтвердили сходимость наблюдаемых и моделируемых значений [17–19].

В районе верхнего участка бассейна р. Оронт в Сирии было проведено несколько исследований с целью моделирования поверхностного стока, но ни одно из них не осуществлялось для моделирования поверхностного стока с помощью ПО MIKE 11 NAM, которое обеспечивает преимущества моделей искусственного интеллекта [20, 21].

Цель данного исследования — проверка возможностей и надежности программы MIKE 11 NAM для моделирования стока верхнего участка бассейна р. Оронт в Сирии при условии использования моделей искусственного интеллекта для «заполнения пробелов» во временной последовательности движения стоков.

МАТЕРИАЛЫ И МЕТОДЫ

Место исследования и наличие данных

Настоящее исследование выполнялось в районе верхнего участка бассейна р. Оронт в Сирии, на территории, простирающейся от сирийско-ливанской границы до озера Каттина. Авторы использовали информацию по поверхностному стоку, полученную на станциях Аль-Джавадия и Аль-Амири с декабря 1987 по май 2011 гг., т.е. сведения за 266 месяцев.

Искусственная нейронная сеть

Искусственные нейронные сети — это математические модели, структура и метод обработки которых имитируют структуру и метод обработки данных нейронными сетями мозга человека [22]. ИНС состоит из входного и выходного слоя; она может состоять из одного или нескольких скрытых слоев, а ИНС с обратным распространением являются наиболее популярными [23]. Данные всегда упорядочиваются в пределах одной области, что облегчает процесс обучения ИНС для разработки наилучшей модели. Упорядоченные значения возвращаются в нормальное состояние после обучения модели, чтобы получить пригодные и сопоставимые значения для других моделей. Информация делится на три множества для обучения, валидации и проверки надежности модели.

Система нечетких логических выводов (НЛВ)

Теория нечеткой логики была разработана для моделирования неопределенных и неточных проблем. Она основана на концепции нечеткого множества, которая дополняет классическое множество, где элементы нечетких множеств могут частично принадлежать этим множествам. Разработка нечеткой модели зависит от трех ключевых этапов: фазификации, операции нечеткого вывода и дефазификации. При фазификации классические входные данные преобразуются в нечеткие с помощью набора функций принадлежности, таких как тригонометрическая принадлежность, принадлежность трапеции и принадлежность Гаусса [16]. Набор нечетких правил «если – то» далее реализуется в нечетких входах для получения нечетких выходов, которые на третьем этапе преобразуются в понятные классические выходы, пригодные для использования в других моделях или сравнимые с выходами, которые применяются иными методами.




Рис. 1. Структура модели MIKE NAM [16]

Табл. 1. Основные параметры модели MIKE 11 NAM [16]

Параметр	Описание
$U_{\max}$	Верхний предел количества воды в поверхностном водохранилище. Это содержание воды в перехватывающих водохранилищах, количество воды во впадинах и поверхностных (наливных) водохранилищах. Параметр постоянно уменьшается за счет испарения, перелива и фильтрации. Типичные значения $U_{\max}$ находятся в диапазоне 10–20 мм
$L_{\max}$	Максимальное содержание воды в нижней зоне водохранилища. Представляет собой влажность почвы под земной поверхностью, из которой растения берут воду для испарения. Как правило, $U = 0,1 L$, притом что L находится в диапазоне 100–300 мм
CQOF	Коэффициент стока. Значения CQOF находятся в диапазоне от 0 до 1 и определяют распределение избыточных осадков между поверхностным стоком и фильтрацией
CK_{IF}	Постоянная времени для учета перелива из поверхностного водохранилища. Является доминирующим параметром маршрутизации стока, поскольку $CK_{IF} > CK_{12}$. Значения CK_{IF} находятся в диапазоне 500–1000 ч
CK_{12}	Постоянная времени для поверхностного стока и маршрутизации перелива. Поверхностный сток и переливающаяся вода проходят через два последовательных линейных резервуара с постоянными времени CK_{12} . Стандартные значения находятся в диапазоне от 3 до 48 ч
TOF, TIF, TG	Пороговые значения для поверхностного стока, перелива и подпитки подземных вод соответственно. Поток генерируется только в том случае, если относительное содержание влаги в нижней зоне (водоносном горизонте) превышает пороговое значение. Их значения находятся в диапазоне от 0 до 1
CK_{BF}	Постоянная времени для маршрутизации базового стока. Базовый сток из водоносного горизонта подземных вод генерируется с использованием линейной модели водохранилища с постоянной времени CK_{BF} . Значения CK_{BF} находятся в диапазоне от 500 до 5000 ч

MIKE 11 NAM

MIKE 11 NAM моделирует процессы дождевого стока в пределах водосборного бассейна, что является частью процесса моделирования MIKE 11 River [15]. На рис. 1 показана структура модели MIKE NAM, а в табл. 1 приведены основные параметры модели MIKE 11 NAM.

Существует множество основных данных, необходимых для построения и отладки модели Mike, это информация для подготовки модели — площадь водосбора, топография местности и свойства почвы, а также постоянные временные величины и пороговые значения наземного потока, перелива и основного потока, помимо климатических сведений, таких как осадки и испарение, требуемых для отладки модели [19].

РЕЗУЛЬТАТЫ

Искусственная нейронная сеть

Вначале проведено аналитическое исследование данных, затем они были упорядочены и разделены на три множества для обучения, валидации и тестирования в соответствии с пропорцией 70:15:15 с по-

мощью функции блока разделения в MATLAB, что означает, что количество используемой информации составляет 186:40:40 месяцев в одном порядке. Эта функция сохраняет сведения, используемые в каждом из множеств, чтобы повысить достоверность сравниваемых результатов.

Разработано и обучено большое количество моделей ИНС. Процесс сопровождался изменениями в их архитектуре, функциях и алгоритмах, необходимыми для обеспечения максимально точных результатов. В этих моделях во входном слое использовались два нейрона, представляющие собой сток на целевой станции в течение времени $t-1$ и сток на другой станции в течение времени t , в то время как выходной слой содержал один нейрон, представляющий сток за время t .

Результаты показали, что ИНС с прямым и обратным распространением являются самыми лучшими. В табл. 2 представлены результаты, полученные в ходе обучения, проверки и тестирования множеств данных лучших моделей ИНС на станциях Аль-Джавадия и Аль-Амири. Эта функция сохраняет данные каждого из множеств, чтобы повысить надежность сравнения результатов.

Табл. 2. Значения критериев эффективности моделей ИНС

Номер	Топология сети (архитектура)	Обучение		Валидация		Тестирование	
		<i>R</i> , %	RMSE, м³/с	<i>R</i> , %	RMSE, м³/с	<i>R</i> , %	RMSE, м³/с
<i>Лучшие модели ИНС для оценки месячного стока на станции Аль-Джавадия</i>							
(А)	2-12-1	88,941	1,4833	93,986	0,8383	94,795	0,7331
Б	2-6-1	88,099	1,5455	93,595	0,9670	94,4158	0,9867
<i>Лучшие модели ИНС для оценки месячного стока на станции Аль-Амири</i>							
А	2-8-1	92,729	1,0499	95,755	0,7053	78,757	1,1849
Б	2-10-1	92,842	1,0650	95,433	0,6797	74,738	1,1575
(С)	2-11-1	93,462	1,0389	95,797	0,6789	77,418	1,1692

Как показано в табл. 2, лучшая модель ИНС на станции Аль-Джавадия имеет 12 нейронов в скрытом слое, что означает коэффициент корреляции 94,795 % за период тестирования; среднеквадратичное значение ошибки составляет 0,7331 м³/с за период тестирования. Лучшая модель ИНС на станции Аль-Амири имеет 11 нейронов в скрытом слое, что означает коэффициент корреляции 77,418 % за период тестирования, а среднеквадратичное значение ошибки составляет 1,1692 м³/с за тот же период.

Система нечеткого логического вывода (НЛВ)

На этом этапе для повышения достоверности сравнения результатов применен тот же метод разделения данных, который использовался для построения ИНС. Затем было построено большое количество моделей нечетких выводов с изменением количества и типа функций принадлежности. Кроме

того, использовались модели искусственного интеллекта для достижения оптимальных параметров нечеткой модели, которая генерирует наиболее точные результаты.

В табл. 3 показаны результаты лучших моделей НЛВ, полученных во время обучения, проверки и тестирования на станциях Аль-Джавадия и Аль-Амири.

Как видно из табл. 3, лучшая модель НЛВ на станции Аль-Джавадия основана на четырех функциях принадлежности Гаусса, что означает коэффициент корреляции 94,789 % за период тестирования, а также среднеквадратичное значение ошибки 0,7791 м³/с за период тестирования. Лучшая модель НЛВ на станции Аль-Амири основана на трех функциях принадлежности Гаусса, что означает коэффициент корреляции 77,875 % за период тестирования, а также значение среднеквадратичной ошибки 1,2602 м³/с за тот же период.

Табл. 3. Значения критериев эффективности моделей НЛВ

Количество функций принадлежности	Тип функции принадлежности	Обучение		Валидация		Тестирование	
		R, %	RMSE, м³/с	R, %	RMSE, м³/с	R, %	RMSE, м³/с
Лучшие модели НЛВ для оценки месячного стока на станции Аль-Джавадия							
(4)	Гаусс	91,494	1,2368	87,150	1,2770	94,789	0,7791
3	Гаусс	91,131	1,2617	90,772	1,1222	95,230	0,8022
4	Треугольной формы	91,488	1,2372	88,336	1,2367	95,027	0,7928
Лучшие модели НЛВ для оценки месячного стока на станции Аль-Амири							
(3)	Гаусс	93,523	0,9684	95,307	0,7826	77,875	1,2602
4	Треугольной формы	94,258	0,9135	94,306	0,8157	76,853	1,2954

Сравнение моделей ИНС и НЛВ

Сравнив результаты лучших моделей ИНС и НЛВ в табл. 2 и 3, или график результатов на рис. 2, мы обнаруживаем высокую сходимость результатов при высоких значениях коэффициентов оценки модели, что подтверждает надежность обеих моделей, а также их способность оценивать и прогнозировать величину стока на исследуемой территории с небольшим перевесом в сторону моделей ИНС.




Рис. 2. Сравнение реальных значений и значений, смоделированных моделями ИНС и НЛВ во время валидации и тестирования

MIKE 11 NAM

Сначала модели ИНС, полученные на предыдущих этапах, использовались для подготовки полных данных по поверхностному стоку на станциях Аль-

Джавадия и Аль-Амири, а затем эта информация введена в рабочую среду программы MIKE.

В связи с отсутствием сведений и невозможностью получить необходимые точные параметры для модели, а также выйти на самые лучшие параметры, был применен метод проб и ошибок с большим количеством итерационных циклов (более 8000). В табл. 4 приведены параметры, принятые в модели Mike для верхнего участка бассейна р. Оронт.

Табл. 4. Основные параметры модели для бассейна р. Оронт

Параметр	Значение
$U_{\max}$	10
$L_{\max}$	100
CQOF	0,963
CK_{IF}	911,524
CK_I	10
TOF	0,988
TIF	0
TG	0
CK_{BF}	4000

Затем полученные значения поверхностного стока представлены вместе с измеренными значениями, как показано на рис. 3, на рис. 4 приведено сравнение данных наблюдаемого и смоделированного стока.

По результатам сравнения видно, что полученные значения поверхностного стока далеки от сходимости, выявлены существенные различия между наблюдаемыми и смоделированными значениями стока, так как значение среднеквадратичных ошибок достигло 5,482 м³/с, и это значение слишком велико.




Рис. 3. Данные наблюдаемого и смоделированного стока




Рис. 4. Накопленные данные о наблюдаемом и смоделированном стоке

ЗАКЛЮЧЕНИЕ И ОБСУЖДЕНИЕ

Сначала было проведено статистическое исследование использованных данных, затем они упорядочены и разделены на три множества для обучения, валидации и тестирования. Модели ИНС построены и обучены в соответствии с различными параметрами, и они показали хорошие результаты: лучшая модель ИНС на станции Аль-Джавадия содержит 12 нейронов в скрытом слое, что обеспечило коэффициент корреляции 94,795 % за время тестирования, а также значение среднеквадратичной ошибки 0,7331 м³/с за тот же период. Лучшая модель ИНС на станции Аль-Амири имеет 11 нейронов в скрытом слое, что означает коэффициент корреляции 77,418 % за период тестирования, а также значение среднеквадратичной ошибки 1,1692 м³/с за тот же период. Аналогичным образом построено большое количество моделей нечеткого вывода; количество и тип функций принадлежности изменялись с использованием тех же данных в трех

множествах, задействованных при построении нейронных моделей. Также получены хорошие результаты: на станции Аль-Джавадия лучшая модель НЛВ основана на четырех функциях принадлежности Гаусса, что обеспечило коэффициент корреляции 94,789 % за период тестирования, а также значение среднеквадратичной ошибки 0,7791 м³/с за тот же период. Лучшая модель НЛВ на станции Аль-Амири основана на трех функциях принадлежности Гаусса, что обеспечило коэффициент корреляции 77,875 % за период тестирования, а значение среднеквадратичной ошибки составило 1,2602 м³/с за тот же период. Следовательно, результаты искусственных нейронных сетей и моделей нечеткого вывода были достаточно высокими и надежными для оценки и прогнозирования величины стока на исследуемой территории с небольшим перевесом в сторону моделей ИНС. После этого модели ИНС применялись для восполнения недостающих данных, которые введены в модель Mike. Затем

задействован метод проб и ошибок для обеспечения наилучших параметров модели и получения лучших значений поверхностного стока, но эти значения были далеки от реальных и отличались серьезными ошибками из-за недостатка информации в районе исследования. Согласно более ранним исследованиям, плохие результаты получены и для модели Mike при недостаточности данных [16].

Использованные модели искусственного интеллекта показали высокую надежность при оценке

и прогнозирования значений стока в верхнем участке бассейна р. Оронт с небольшим перевесом в сторону моделей ИНС. Что касается результатов применения модели Mike, то они оказались неприемлемыми из-за высоких значений ошибок вследствие недостаточного количества имеющихся сведений. Авторы настоящего исследования рекомендуют продолжить работу в области гидрологического моделирования и моделирования связанных с ним факторов, особенно в случае недостаточности данных.

СПИСОК ИСТОЧНИКОВ

1. Биденко С.И., Храмов И.С., Шилин М.Б. Оценка территориальной ситуации с использованием искусственных нейронных сетей // Ученые записки РГГМУ. 2019. № 54. С. 109–123. DOI: 10.33933/2074-2762-2019-54-109-123
2. Гордеева С.М., Малинин В.Н. Использование Data Mining в задаче гидрометеорологического прогнозирования // Ученые записки РГГМУ. 2016. № 44. С. 30–44.
3. Гордеева С.М., Малинин В.Н. О предвычислении годового стока крупных рек Европейской части России на основе метода деревьев решений (decision trees) // Ученые записки РГГМУ. 2018. № 50. С. 53–65.
4. Зеленцов В.А., Потрясаев С.А., Пиманов И.Ю., Пономаренко М.Р. Автоматизация мониторинга и комплексного моделирования гидрологической обстановки в бассейнах рек // Ученые записки РГГМУ. 2019. № 55. С. 74–85. DOI: 10.33933/2074-2762-2019-55-74-85
5. Карапетян Т.А. Использование искусственных нейронных сетей для оценки и прогнозирования речных стоков // Молодой ученый. 2019. № 19 (257). С. 29–33.
6. Шитиков В.К., Зинченко Т.Д., Головатюк Л.В. Нейросетевые методы оценки качества поверхностных вод по гидробиологическим показателям // Известия Самарского научного центра Российской академии наук. 2002. Т. 4. № 2. С. 280–289.
7. Mahabir C., Hicks F.E., Fayek A.R. Application of fuzzy logic to forecast seasonal runoff // Hydrological Processes. 2003. Vol. 17. Issue 18. Pp. 3749–3762. DOI: 10.1002/hyp.1359
8. Şen Z., Altunkaynak A. A comparative fuzzy logic approach to runoff coefficient and runoff estimation // Hydrological Processes. 2006. Vol. 20. Issue 9. Pp. 1993–2009. DOI: 10.1002/hyp.5992
9. Lohani A.K., Goel N.K., Bhatia K.K.S. Comparative study of neural network, fuzzy logic and linear transfer function techniques in daily rainfall-runoff modelling under different input domains // Hydrological Processes. 2011. Vol. 25. Issue 2. Pp. 175–193. DOI: 10.1002/hyp.7831
10. Tayfur G., Singh V.P. ANN and Fuzzy Logic Models for Simulating Event-Based Rainfall-Runoff // Journal of Hydraulic Engineering. 2006. Vol. 132. Issue 12. Pp. 1321–1330. DOI: 10.1061/(asce)0733-9429(2006)132:12(1321)
11. Wang K.H., Altunkaynak A. Comparative Case Study of Rainfall-Runoff Modeling between SWMM and Fuzzy Logic Approach // Journal of Hydrologic Engineering. 2012. Vol. 17. Issue 2. Pp. 283–291. DOI: 10.1061/(asce)he.1943-5584.0000419
12. Saade J., Atieh M., Ghanimeh S., Golmohammadi G. Modeling Impact of climate change on Surface Water Availability Using SWAT Model in a Semi-Arid Basin: Case of El Kalb River, Lebanon // Hydrology. 2021. Vol. 8. Issue 3. P. 134. DOI: 10.3390/hydrology8030134
13. Haddad A., Remini B. Extreme rainfall-runoff events modeling by HEC-HMS model for Koudiet Rosfa Watershed, Algeria // GeoScience Engineering. 2021. Vol. 67. Issue 4. Pp. 144–155. DOI: 10.35180/gse-2021-0060
14. Hamdan A.N.A., Almuktar S., Scholz M. Rainfall-Runoff modeling using the HEC-HMS Model for the Al-Adhaim river catchment, Northern Iraq // Hydrology. 2021. Vol. 8. Issue 2. P. 58. DOI: 10.3390/hydrology8020058
15. Tan K.M., Seow W.K., Wang C.L., Kew H.J., Parasuraman S.B. Evaluation of performance of Active, Beautiful and Clean (ABC) on stormwater runoff management using MIKE URBAN: a case study in a residential estate in Singapore // Urban Water Journal. 2019. Vol. 16. Issue 2. Pp. 156–162. DOI: 10.1080/1573062X.2019.1634744
16. Гебрехивот А.А., Козлов Д.В. Оценка применимости гидрологического модуля MIKE 11-NAM для моделирования дождевого стока в малоизученном речном бассейне // Вестник МГСУ. 2020. Т. 15. № 7. С. 1030–1046. DOI: 10.22227/1997-0935.2020.7.1030-1046
17. Aredo M.R., Hatiye S.D., Pingale S.M. Modeling the rainfall-runoff using MIKE 11 NAM model in Shaya catchment, Ethiopia // Modeling Earth Systems and Environment. 2021. Vol. 7. Issue 4. Pp. 2545–2551. DOI: 10.1007/s40808-020-01054-8

18. Ghosh A., Roy M.B., Roy P.K. Evaluating the performance of MIKE NAM model on rainfall–runoff in lower Gangetic floodplain, West Bengal, India // *Modeling Earth Systems and Environment*. 2022. Vol. 8. Issue 3. Pp. 4001–4017. DOI: 10.1007/s40808-021-01347-6
19. Shamsudin S., Hashim N. Rainfall runoff simulation using MIKE11 NAM // *Journal Kejuruteraan Awam (Journal of Civil Engineering)*. 2002. Vol. 15. Issue 2.
20. Issa M. The relationship between river flow and precipitation in the Orontes Basin // *Damascus University Journal*. 2015. Vol. 31. Issue 2.
21. Hamdan Y., Layos E., Mohammed I. Identify indicators of climate change through the analysis of the amount of rain on upper basin for Orontes River // *Al-Baath University Journal*. 2017. Vol. 39. Issue 43.
22. Chen S.M., Wang Y.M., Tsou I. Using artificial neural network approach for modelling rainfall–runoff due to typhoon // *Journal of Earth System Science*. 2013. Vol. 122. Issue 2. Pp. 399–405. DOI: 10.1007/s12040-013-0289-8
23. Nourani V., Gokcekus H., Gelete G. Estimation of suspended sediment load using artificial intelligence-based ensemble model // *Complexity*. 2021. Vol. 2021. Pp. 1–19. DOI: 10.1155/2021/6633760

Поступила в редакцию 16 ноября 2022 г.

Принята в доработанном виде 7 декабря 2022 г.

Одобрена для публикации 7 декабря 2022 г.

О Б А В Т О Р А Х: **Алаа Слейман** — аспирант кафедры гидравлики и гидротехнического строительства; **Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ);** 129337, г. Москва, Ярославское шоссе, д. 26; alaa-slieman@hotmail.com;

Дмитрий Вячеславович Козлов — доктор технических наук, профессор, заведующий кафедрой гидравлики и гидротехнического строительства; **Национальный исследовательский Московский государственный строительный университет (НИУ МГСУ);** 129337, г. Москва, Ярославское шоссе, д. 26; РИНЦ ID: 5878-6674, Scopus: 36787104800, ResearcherID: B-4808-2016, ORCID: 0000-0002-9440-0341; kozlovdv@mail.ru.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.

INTRODUCTION

The ability of runoff modeling is an essential step in the hydrologic modeling process and therefore water balance studies and all studies related to water resources, and it also helps in the integrated management of water resources in the study area.

In recent years, artificial intelligence models have received great attention by researchers, and many studies have been conducted into the possibility of using these models in the field of water resources and hydrology. Where a number of researchers conducted studies to verify the possibility of using artificial neural networks in predicting and estimating the values of surface runoff and obtained good results [1–6]. Others used fuzzy inference models in modeling and estimating surface runoff [7, 8], while comparison was also made between artificial neural networks models and fuzzy inference models in surface runoff modeling, and close results were obtained [9, 10]. Also (K.H. Wang and A. Altunkaynak, 2012) compared the storm water management model (SWMM) and the fuzzy inference models, and the results showed the superiority of the fuzzy inference models [11].

On the other hand, researchers were interested in using hydrological models such as HEC HMS and Arc SWAT [12–14], also several studies of hydrologic modeling were also conducted using Mike model, such as (Kok et al., 2019) who used a MIKE URBAN to evaluate the performance of Active, Beautiful and Clean (ABC)

on stormwater runoff management, and the results showed a good agreement with the required values [15]. (Anghesom and Kozlov 2020) also used the MIKE 11 NAM to assess applicability of climate reanalysis data to rainfall runoff modelling in the poorly studied river basin in Eritrea, and the results indicated an overestimation of rainfall values [16]. Other studies showed the ability of Mike’s model to model surface runoff and convergence between the observed and simulated values [17–19].

In the study area in the upper Orontes Basin in Syria, a number of studies were conducted for modeling of surface runoff, but none of them were conducted for surface runoff modeling using the MIKE 11 HAM and the possibility of benefiting from artificial intelligence models in this model [20, 21].

Therefore, this study aims to verify the ability and reliability of the MIKE 11 NAM program in modeling runoff, in the upper basin of Orontes River in Syria, with the use of artificial intelligence models to fill the gaps in runoff time series.

MATERIALS AND METHODS

Study site and data availability

This study was conducted on the upper Orontes Basin in Syria, within the region extending from the Syrian-Lebanese border to Lake Kattina, and used surface runoff data for Al-Jawadiyah and Al-Amiri stations from December 1987 to May 2011 was used, consisting of 266 monthly values.

Artificial Neural Network

Artificial neural networks are mathematical models whose structure and method of data processing depend on simulating the structure and method of data processing in neural networks in the human brain [22]. Artificial neural network consists of an input layer and an output layer, and it can contain one or more hidden layers, and feed-forward back propagation artificial neural networks (FFBP ANNs) are the most popular types of neural networks [23]. The data used is always normalized within one domain, which facilitates the training process of the artificial neural network and reaching to the best model. The normalized values are returned to their normal state after the model is trained to obtain usable and comparable values in other models. Also, the data is divided into three data sets for training, validation and testing of the reliability of the model's work.

Fuzzy Inference System

Fuzzy logic theory was developed for modeling of uncertain and imprecise problems. Fuzzy logic theory

is based on the fuzzy set concept which is an extension of the classical set where the elements of fuzzy sets can belong partially to those sets. The building of the fuzzy model depends on three main steps, (Fuzzification, Fuzzy Inference Operations, Defuzzification), in fuzzification, the classical inputs are converted into fuzzy inputs using a set of membership functions such as the trigonometric membership, the trapezoid membership, and the Gauss membership [16]. A set of fuzzy rules (if-then) is then implemented on the fuzzy inputs to obtain fuzzy outputs that are converted in the third stage to understandable classical outputs that can be used in other models or compared with the outputs of other methods.

MIKE 11 NAM

MIKE 11 NAM model works on modeling of rain-fall runoff processes within a catchment which is part of the modeling process within the MIKE 11 River model [15]. The fig. 1 shows structure of the model MIKE NAM and the table 1 shows MIKE 11 NAM model's basic parameters.




Fig. 1. Structure of the model MIKE NAM [16]

Table 1. MIKE 11 NAM model's basic parameters [16]

Parameter	Description
U_{max}	The upper limit of the amount of water in the surface water storage reservoir. It is the water content in interception storage, depression storage and surface storage reservoirs. It is continuously lost to evaporation, interflow and infiltration. The typical values of U_{max} are in the range of 10–20 mm
L_{max}	Maximum water content in the lower zone storage. It represents soil moisture below the surface from which plants take water for transpiration. As a rule, $U = 0.1 L$ where L is in the range of 100–300 mm

Parameter	Description
CQOF	Overland flow runoff coefficient. CQOF values are in the range of 0 and 1 and determine the distribution of excess rainfall between the overland flow and infiltration
CK _{IF}	Time constant for the interflow from the surface storage reservoir. CK _{IF} is the dominant routing parameter of the interflow because CK _{IF} > CK ₁₂ . CK _{IF} values are in the range of 500–1,000 hours
CK ₁₂	Time constant for overland flow and interflow routing. The overland flow and the interflow are routed through two successive linear reservoirs with time constants CK ₁₂ . Typical values are in the range of 3–48 hours
TOF, TIF, TG	Threshold values for overland flow, interflow and groundwater recharge, respectively. The flow is only generated if the relative moisture content in the lower storage zone is above the threshold value. Their values are in the range of 0–1
CK _{BF}	Time constant for baseflow routing. The baseflow from the groundwater storage reservoir is generated using a linear reservoir model with time constant CK _{BF} . CK _{BF} values being in the range of 500–5,000 hours

There is a set of basic data required to build and calibrate the Mike model, including the model preparation data, such as the area of the watershed, the topography of the area and the soil properties in it, and the model data such as time constants and threshold values of overland flow, interflow and baseflow, in addition to climatic data such as precipitation and evaporation, and certainly it will be required to runoff data for model calibration [19].

RESULTS

Artificial Neural Network

In the beginning, an analytical study was conducted for the used data, then the data was normalized and then divided into three datasets for training, validation and testing according to the ratios (70:15:15 %), respectively, using the divide block function in MATLAB, which

meaning that the number of used data is (186:40:40 month) in the order, and this function saves the data which used in each of the datasets, and this increases the reliability of the comparison between the results.

A large number of artificial neural network models have been prepared and trained with the change in the architecture, functions and algorithms used in them to reach the most accurate results. In these models, two neurons were used in the input layer representing the runoff at the target station during time $t-1$ and the runoff at the other station during time t , while the output layer contained one neuron representing the runoff during time t .

The results showed that feed forward and back propagation artificial neural networks (FFBP ANNs) are the best, and table 2 shows the results of the best ANN models obtained during the training, validation and testing datasets at both Al-Jawadiyah and Al-Amiri stations.

Table 2. The table presents Evaluation factors of the best obtained ANNs models

Number	ANN architecture	Train		Validation		Test	
		<i>R</i> , %	RMSE, m ³ /s	<i>R</i> , %	RMSE, m ³ /s	<i>R</i> , %	RMSE, m ³ /s
<i>The best ANNs models for estimation the monthly runoff at Al-Jawadiyah station</i>							
(A)	2-12-1	88.941	1.4833	93.986	0.8383	94.795	0.7331
B	2-6-1	88.099	1.5455	93.595	0.9670	94.4158	0.9867
<i>The best ANNs models for estimation the monthly runoff at Al-Amiri station</i>							
A	2-8-1	92.729	1.0499	95.755	0.7053	78.757	1.1849
B	2-10-1	92.842	1.0650	95.433	0.6797	74.738	1.1575
(C)	2-11-1	93.462	1.0389	95.797	0.6789	77.418	1.1692

As shown in the table 2, the best ANN model at Al-Jawadiyah station contains 12 neurons in the hidden layer, which gave correlation coefficient 94.795 % during the testing period, as well as the root mean square error value is 0.7331 m³/s during the testing period, and the best ANN model at Al-Amiri station contains 11 neurons in the hidden layer, which gave correlation coefficient 77.418 % during the testing period, and the root mean square error value is 1.1692 m³/s in the same period.

Fuzzy Inference System

At this stage, the same method of data dividing used in building of artificial neural networks was relied upon in order to increase the reliability of the comparison between the results. Then, a large number of fuzzy inference models were built with changing the number and type of membership functions. Also, artificial intelligence models were used in order to reach the optimal parameters of the fuzzy model, which gives the most accurate results possible.

Table 3. The table presents Evaluation factors of the best obtained FIS models

Number of membership functions	Type of membership functions	Train		Validation		Test	
		R, %	RMSE, m ³ /s	R, %	RMSE, m ³ /s	R, %	RMSE, m ³ /s
The best FIS models for estimation the monthly runoff at Al-Jawadiyah station							
(4)	Gauss mf	91.494	1.2368	87.150	1.2770	94.789	0.7791
3	Gauss mf	91.131	1.2617	90.772	1.1222	95.230	0.8022
4	Tri mf	91.488	1.2372	88.336	1.2367	95.027	0.7928
The best FIS models for estimation the monthly runoff at Al-Amiri station							
(3)	Gauss mf	93.523	0.9684	95.307	0.7826	77.875	1.2602
4	Tri mf	94.258	0.9135	94.306	0.8157	76.853	1.2954


Table 3 shows the results of the best FIS models obtained during the training, validation and testing datasets at both Al-Jawadiyah and Al-Amiri stations.

As shown in the table 3, the best FIS model at Al-Jawadiyah station based on four Gauss membership functions, which gave correlation coefficient 94.789 % during the testing period, as well as the root mean square error value is 0.7791 m³/s during the testing period, and the best FIS model at Al-Amiri station based on three Gauss membership functions, which gave correlation coefficient 77.875 % during the testing period, and

the root mean square error value is 1.2602 m³/s in the same period.

Comparison between ANN and FIS Models

By comparing between the results of the best ANNs models and FIS models that were obtained as shown in tables 2 and 3, or through the graph of the results as shown in fig. 2, we find the high convergence between the results with high values of the model evaluation coefficients, which shows the reliability of both models and its ability to estimate and predict of runoff values in the study area with a slight preference for artificial neural network models.

**Fig. 2.** The figure presents comparison between the real values and the values generated by the ANN and FIS models during the validation and testing periods

MIKE 11 NAM

Initially, the artificial neural network models obtained in the previous steps were used to prepare complete data series for surface runoff at Al-Jawadiya and Al-Amiri stations, and then these data were entered into the working environment of the MIKE program.

Due to the lack of existing data and the inability to obtain the required parameters for the model accurately, and to reach the best possible parameters, the trial-and-

error method was used with a large number of iterative cycles (more than 8,000 iterative cycles). Table 4 shows the parameters adopted in the Mike model for the upper basin of the Orontes River.

Then the resulting surface runoff values were represented with the measured values as shown in fig. 3, while fig. 4 shows the comparison between observed and simulated accumulated runoff data.

Table 4. Model's basic parameters for the ASI-ORONTES river basin

Parameter	Value	Parameter	Value	Parameter	Value
$U_{\max}$	10	CK _{IF}	911.524	TIF	0
$L_{\max}$	100	CK1	10	TG	0
CQOF	0.963	TOF	0.988	CK _{BF}	4,000




Fig. 3. Observed and simulated runoff data




Fig. 4. Observed and simulated accumulated runoff data

By comparison it is clear that the resulting values of surface runoff are not good and there are large differences between observed and simulated accumulated runoff values, as the value of the root mean squares of errors reached $5.482 \text{ m}^3/\text{s}$, which is a high and not good value.

DISCUSSION AND CONCLUSIONS

At first, a statistical study was conducted for the data used, then the data was normalized and divided into three datasets for training, validation and testing. The models of artificial neural networks were built and trained according to various parameters and showed good results, that as the best ANN model at Al-Jawadiyah station contains 12 neurons in the hidden layer, which gave correlation coefficient 94.795 % during the testing period, as well as the root mean square error value is $0.7331 \text{ m}^3/\text{s}$ during the testing period, and the best ANN model at Al-Amiri station contains 11 neurons in the hidden lay-

er, which gave correlation coefficient 77.418 % during the testing period, and the root mean square error value is $1.1692 \text{ m}^3/\text{s}$ in the same period. Likewise, a large number of fuzzy inference models were built with changing the number and type of membership functions and using the same data in the three datasets which were used in building of neural models. Also, the results were good that as the best FIS model at Al-Jawadiyah station based on four Gauss membership functions, which gave correlation coefficient 94.789 % during the testing period, as well as the root mean square error value is $0.7791 \text{ m}^3/\text{s}$ during the testing period, and the best FIS model at Al-Amiri station based on three Gauss membership functions, which gave correlation coefficient 77.875 % during the testing period, and the root mean square error value is $1.2602 \text{ m}^3/\text{s}$ in the same period. Thus, the results of both artificial neural networks and fuzzy inference models were good and highly reliable for estimating and predicting runoff values in the study area with a slight

preference for artificial neural network models. After that, the obtained artificial neural network models were used to complete the missing data and enter it into the Mike model, then the trial-and-error method was used in order to reach the best parameters of the model and get the best values for surface runoff, but these values were far from the real values and carried high errors due to the lack of data available in the study area, we also note from previous studies that also obtained poor results for the Mike model in cases of lack of data [16].

The used artificial intelligence models showed high reliability for estimating and predicting of runoff values in the upper Orontes Basin with a slight preference for artificial neural network models. As for the results of using Mike's model, it was unacceptable with high error values, due to the insufficient data available. This study recommends to continue the study in the field of hydrologic modeling and modeling of the factors associated with it, especially under the conditions of lack of data.

REFERENCES

1. Bidenko S.I., Khramov I.S., Shilin M.B. Assessment of the territorial situation using artificial neural networks. *Proceedings of the Russian State Hydrometeorological University*. 2019; 54:109-123. DOI: 10.33933/2074-2762-2019-54-109-123 (rus.).
2. Gordeeva S.M., Malinin V.N. Use of Data Mining in hydrometeorological forecasting. *Proceedings of the Russian State Hydrometeorological University*. 2016; 44:30-44. (rus.).
3. Gordeeva S.M., Malinin V.N. On predicting annual runoff of large rivers of European Russia based on decision trees method. *Proceedings of the Russian State Hydrometeorological University*. 2018; 50: 53-65. (rus.).
4. Zelentsov V.A., Potriasaev S.A., Pimanov I.Yu., Ponomarenko M.R. Automation of monitoring and integrated modeling of hydrological situation in river basins. *Proceedings of the Russian State Hydrometeorological University*. 2019; 55:74-85. DOI: 10.33933/2074-2762-2019-55-74-85 (rus.).
5. Karapetyan T.A. Using artificial neural networks to assess and predict river flows. *Young Scientist*. 2019; 19(257):29-33. (rus.).
6. Shitikov V.K., Zinchenko T.D., Golovatykh L.V. Methods of neural networks for estimation of superficial water's quality by usage of hydrobiological exponents. *Izvestia of Samara Scientific Center of the Russian Academy of Sciences*. 2002; 4(2):280-289. (rus.).
7. Mahabir C., Hicks F.E., Fayek A.R. Application of fuzzy logic to forecast seasonal runoff. *Hydrological Processes*. 2003; 17(18):3749-3762. DOI: 10.1002/hyp.1359
8. Şen Z., Altunkaynak A. A comparative fuzzy logic approach to runoff coefficient and runoff estimation. *Hydrological Processes*. 2006; 20(9):1993-2009. DOI: 10.1002/hyp.5992
9. Lohani A.K., Goel N.K., Bhatia K.K.S. Comparative study of neural network, fuzzy logic and linear transfer function techniques in daily rainfall-runoff modelling under different input domains. *Hydrological Processes*. 2011; 25(2):175-193. DOI: 10.1002/hyp.7831
10. Tayfur G., Singh V.P. ANN and Fuzzy Logic Models for Simulating Event-Based Rainfall-Runoff. *Journal of Hydraulic Engineering*. 2006; 132(12):1321-1330. DOI: 10.1061/(asce)0733-9429(2006)132:12(1321)
11. Wang K.H., Altunkaynak A. Comparative Case Study of Rainfall-Runoff Modeling between SWMM and Fuzzy Logic Approach. *Journal of Hydrologic Engineering*. 2012; 17(2):283-291. DOI: 10.1061/(asce)he.1943-5584.0000419
12. Saade J., Atieh M., Ghanimeh S., Golmohammadi G. Modeling Impact of Climate Change on Surface Water Availability Using SWAT Model in a Semi-Arid Basin: Case of El Kalb River, Lebanon. *Hydrology*. 2021; 8(3):134. DOI: 10.3390/hydrology8030134
13. Haddad A., Remini B. Extreme Rainfall-Runoff Events Modeling by HEC-HMS Model for Koudiet Rosfa Watershed, Algeria. *GeoScience Engineering*. 2021; 67(4):144-155. DOI: 10.35180/gse-2021-0060
14. Hamdan A.N.A., Almuktar S., Scholz M. Rainfall-Runoff Modeling Using the HEC-HMS Model for the Al-Adhaim River Catchment, Northern Iraq. *Hydrology*. 2021; 8(2):58. DOI: 10.3390/hydrology8020058
15. Tan K.M., Seow W.K., Wang C.L., Kew H.J., Parasuraman S.B. Evaluation of performance of Active, Beautiful and Clean (ABC) on stormwater runoff management using MIKE URBAN: a case study in a residential estate in Singapore. *Urban Water Journal*. 2019; 16(2):156-162. DOI: 10.1080/1573062X.2019.1634744
16. Ghebrehiwot A.A., Kozlov D.V. Assessment of applicability of mike 11-nam hydrological module for rainfall runoff modelling in a poorly studied river basin. *Vestnik MGSU [Monthly Journal on Construction and Architecture]*. 2020; 15(7):1030-1046. DOI: 10.22227/1997-0935.2020.7.1030-1046 (rus.).
17. Aredo M.R., Hatiye S.D., Pingale S.M. Modeling the rainfall-runoff using MIKE 11 NAM model in Shaya catchment, Ethiopia. *Modeling Earth Systems and Environment*. 2021; 7(4):2545-2551. DOI: 10.1007/s40808-020-01054-8
18. Ghosh A., Roy M.B., Roy P.K. Evaluating the performance of MIKE NAM model on rainfall-runoff in lower Gangetic floodplain, West Bengal, India. *Modeling Earth Systems and Environment*. 2022; 8(3):4001-4017. DOI: 10.1007/s40808-021-01347-6
19. Shamsudin S., Hashim N. Rainfall runoff simulation using MIKE11 NAM. *Journal Kejuruteraan Awam (Journal of Civil Engineering)*. 2002; 15(2).

20. Issa M. The relationship between river flow and precipitation in the Orontes Basin. *Damascus University Journal*. 2015; 31(2).
21. Hamdan Y., Layos E., Mohammed I. Identify indicators of climate change through the analysis of the amount of rain on upper basin for Orontes River. *Al-Baath University Journal*. 2017; 39(43).
22. Chen S.M., Wang Y.M., Tsou I. Using artificial neural network approach for modelling rainfall–runoff due to typhoon. *Journal of Earth System Science*. 2013; 122(2):399-405. DOI: 10.1007/s12040-013-0289-8
23. Nourani V., Gokcekus H., Gelete G. Estimation of Suspended Sediment Load Using Artificial Intelligence-Based Ensemble Model. *Complexity*. 2021; 2021:1-19. DOI: 10.1155/2021/6633760

Received November 16, 2022.

Adopted in revised form on December 7, 2022.

Approved for publication on December 7, 2022.

B I O N O T E S : **Alaa Slieman** — postgraduate of the Department of Hydraulics and Hydraulic Engineering; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; alaa-slieman@hotmail.com;

Dmitry V. Kozlov — Doctor of Technical Sciences, Professor, Head of the Department of Hydraulics and Hydraulic Engineering; **Moscow State University of Civil Engineering (National Research University) (MGSU)**; 26 Yaroslavskoe shosse, Moscow, 129337, Russian Federation; ID RSCI: 5878-6674, Scopus: 36787104800, ResearcherID: B-4808-2016, ORCID: 0000-0002-9440-0341; kozlovdv@mail.ru.

Contribution of the authors: all of the authors made equivalent contributions to the publication.

The authors declare no conflict of interest.