

Анализ результатов наблюдений и методы расчета гидрофизических полей океана

УДК 551.509.331

В.В. Ефимов, В.Л. Порошков

Применение метода искусственных нейронных сетей для регионализации прогноза осадков в Причерноморском регионе

Выполнена коррекция данных об осадках суточной дискретности с выхода глобальной системы реанализа применительно к наблюдаемым суточным суммам осадков в конкретных географических пунктах Причерноморского региона. Оценки сумм фактических осадков брались из базы данных *European Climate Assessment and Dataset (ECAD)*. Анализировались осадки за три зимних месяца. В качестве рабочего инструмента для исследования связей между регулярными метеопараметрами из реанализа (предикторами) и локальными осадками в конкретном географическом пункте (предиктантом) использовался метод искусственных нейронных сетей (ИНС). Предложен числовой критерий адекватности оценок суточных сумм осадков согласно реанализу и нейросетевой методике. На основании этого критерия демонстрируется большая эффективность ИНС в моделировании осадков по сравнению с реанализом.

Осадки относятся к наименее прогнозируемым параметрам в современных численных прогнозах погоды, в первую очередь в силу своей перемежаемости по пространству и времени. Пространственное разрешение даже в наиболее развитых численных моделях оказывается недостаточным для адекватного описания процессов осадкообразования. Поэтому в настоящее время активно развиваются динамико-статистические методы регионализации прогноза метеорологических параметров: уточнение оценок на выходе численных моделей применительно к конкретным географическим пунктам. В основном эти методы регионализации (*downscaling*) развиваются по двум направлениям. Во-первых, применяются локальные численные модели с высоким пространственным разрешением, которые используют крупномасштабные расчетные поля в качестве граничных условий с учетом региональных характеристик. Другим подходом является статистический даунскейлинг (СД) [1]. Этот метод становится все более популярным благодаря относительной простоте и меньшим затратам по сравнению с использованием локальных моделей. В основном идея СД состоит в использовании наблюдаемых связей (соотношений) между крупномасштабной циркуляцией и локальным климатом для того, чтобы установить статистические модели, связывающие аномалии крупномасштабных полей (предикторы) с аномалиями некоторой локальной климатической переменной (предиктант), например атмосферных осадков.

© В.В. Ефимов, В.Л. Порошков, 2006

В настоящей работе используется эмпирический подход регионализации, основанный на применении техники искусственных нейронных сетей в качестве диагностического инструмента. Искусственные нейронные сети появились в середине 50-х годов как математические модели приближенного описания функционирования нервной системы человека. Первый однослойный персепtron, созданный в 1959 г. [2], использовался для решения некоторых простых задач классификации. С недавнего времени ИНС, построенные на базе многослойного персептрана, стали применяться и в широком спектре проблем метеорологии, включая классификацию облаков [3] и предупреждение торнадо [4]. Преимущества и недостатки ИНС по сравнению с другими статистическими методами обсуждаются в целом ряде работ. Более подробно об этом – в прилагаемых ссылках.

Применение ИНС позволяет найти передаточные функции (в достаточно общем виде, т.е. не только линейные, но и нелинейные связи), которые дают возможность на основе метеорологических предикторов в узлах регулярной сетки глобального массива данных воспроизвести суточные суммы осадков в отдельных пунктах, не совпадающих с узлами сетки реанализа. Предполагается, что такой подход может привести к более совершенным моделям даунскейлинга при изучении региональной изменчивости климата в настоящее время и в будущем.

Данные

Использовались данные из массива *ECAD* [5] ежесуточных наблюдений за осадками (1900–1996 гг.) в двух пунктах вблизи Черного моря: Феодосии и Николаеве. К этим данным был добавлен многолетний массив суточных сумм осадков в Севастополе за 1982–1993 гг. [6].

В качестве предикторов при работе с ИНС использовалась часть данных из системы реанализа *NCEP-NCAR* (*National Center Environmental Prediction / National Center of Atmospheric Research*) [7], в частности двухсроковые записи осадков. Это выходные данные глобальной спектральной модели с приближенным пространственным разрешением $2,5^\circ$ широты на $2,5^\circ$ долготы. В результате общим для всех массивов данных оказался временной период 1982–1993 гг.

На рис.1. проводится сравнение годового хода согласно данным наблюдений и реанализа. Видно, что летний максимум, свойственный континентальным городам, в слабой форме прослеживается в кривой, относящейся к Николаеву. Этого следовало ожидать, так как Николаев находится дальше от моря, чем приморские города Феодосия и Севастополь, в которых летний максимум практически отсутствует. В целом для всех пунктов характерно занижение норм осадков в зимние месяцы по данным реанализа по сравнению с наблюдениями. Кроме того, массив реанализа дает отчетливо выраженный летний максимум для Николаева, отсутствующий в наблюдениях.

Как известно [8, 9], физические механизмы, определяющие формирование осадков, различны в зимние и летние месяцы. Если в зимнее время выпадение осадков в Юго-Восточном секторе Европы связано в основном с прохождением атлантических циклонов, т.е. влиянием крупномасштабной атмосферной циркуляции, то в летнее время оно в большей степени зависит от

локальных условий, таких, как грозовые фронты, конвекция, восходящее движение на крупных неоднородностях рельефа и т.п. Все эти особенности имеют малые горизонтальные масштабы и не воспроизводятся метеорологическими полями при реанализе, в котором благодаря достаточно крупной расчетной сетке они носят подсеточный характер. Поэтому в рамках данной работы ограничимся более простым случаем – всюду в дальнейшем будем рассматривать лишь зимние осадки, т.е. осадки за три зимних месяца (декабрь – февраль).

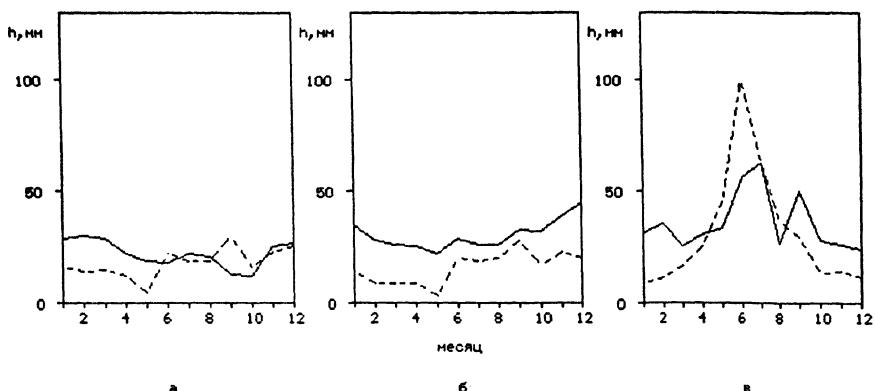


Рис. 1. Годовой ход осадков h согласно наблюдениям (сплошная) и данным реанализа (штриховая)

Основные режимные характеристики осадков. В табл.1 приводятся сведения, характеризующие размеры индивидуальных выборок данных, соотношение сухих и дождливых дней, средний уровень (среднесуточная сумма) и стандартное отклонение в пределах каждой из выборок.

Таблица 1

Основные показатели режима зимних осадков в различных пунктах

Город	n	n_0/n	\bar{x} , мм	σ , мм
Николаев	780	0.718	0.98	2.67
			0.36	
Феодосия	690	0.721	1.0	2.87
			0.61	
Севастополь	1050	0.651	1.22	2.85
			0.47	

Примечание. Здесь n – общее число дней; n_0 – число сухих дней; \bar{x} – средняя величина; σ – стандартное отклонение. Нижние цифры в четвертой колонке относятся к данным реанализа.

Наиболее показательный факт, следующий из табл.1, состоит в том, что во всех пунктах среднесуточная зимняя норма осадков, согласно данным реанализа, существенно занижена по сравнению с данными наблюдений. Таким образом, данные реанализа по суточным суммам осадков нуждаются в

коррективах. Поэтому для более адекватной оценки они требуют применения методов постобработки модельных данных. В качестве такого инструмента и был использован метод ИНС.

Методология

Архитектура ИНС. Использовалась трехслойная сеть прямого распространения – с входным слоем, одним скрытым и выходным слоем, представленным в нашем случае единственным нейроном (более подробно см., например, в [6]). Суть сети прямого распространения состоит в том, что отсутствуют обратные связи между входом и выходом, а также боковые связи между нейронами в пределах одного и того же слоя.

Отметим одну особенность примененной в данной работе сети, отличающую ее от сетей такого типа, а именно: использование различных активирующих функций в разных слоях трехслойной сети [6]. Как правило, в качестве функции активации в обоих слоях берутся сигмоидная функция Ферми или гиперболический тангенс. Согласно [10], в применении к осадкам лучше подходит экспоненциальная функция. Тестирование в нашем случае показало, что наилучший результат достигается, когда на входе используется сигмоидная функция (или гиперболический тангенс, что на практике оказалось несущественным), а в промежуточном слое – экспоненциальная. Итак, единственный выходной нейрон сети z представлялся в виде:

$$z = \exp\left(\sum_{j=1}^m \tilde{w}_j y_j + \tilde{b}\right) - 1, \quad (1)$$

где m – число скрытых нейронов, y – выход j -го нейрона промежуточного слоя. В свою очередь, этот нейрон является нелинейной взвешенной суперпозицией входных нейронов x_i (i – номер нейрона во входном слое):

$$y_j = 2 / (1 + \exp(-(\sum_{i=1}^n w_{ij} x_i + b_j))) - 1, \quad (2)$$

где n – число входных нейронов, а параметры w_{ij}, \tilde{w}_j, b_j и \tilde{b} представляют собой веса и смещения, которые предстоит оптимизировать. Оптимизация, или обучение сети, – итеративный процесс, известный как метод обратного распространения ошибки [11].

Алгоритм обучения. Обучение сети при заданной топологии включает инициализацию и подстройку параметров: матриц весовых коэффициентов и векторов входных смещений по данным обучающей выборки с целью минимизации некоторого функционала. В качестве такого функционала, или целевой функции, как правило, используется (что делается и в настоящей работе) квадратичный функционал ошибки

$$E = \frac{1}{2} \sum_{i=1}^N |z_i - \hat{z}_i|^2, \quad (3)$$

где N – число точек в обучающей выборке; \hat{z}_i – известный выходной вектор i -й точки выборки; z_i – реакция персептрона на соответствующий входной вектор x_i .

В процессе обучения нейронной сети на обучающей выборке данных происходит подбор весов связей, обеспечивающих наименьшую ошибку этого функционала. После обучения обычно проводится оценка результата на контрольной выборке.

Алгоритм обучения нейронной сети на основе обратного распространения ошибки базируется на применении метода градиентного спуска, что означает подстройку весовых коэффициентов следующим образом:

$$\Delta w_{ij}^{(n)} = -\eta \frac{\partial E}{\partial w_{ij}}. \quad (4)$$

Здесь w_{ij} – весовой коэффициент синаптической связи, соединяющей i -й нейрон слоя $n - 1$ с j -м нейроном слоя n ; η – коэффициент скорости обучения. Заметим, что здесь подбор смещений ведется по тому же алгоритму, что и весовых коэффициентов, так как формально смещения равны весовым коэффициентам для синапсов, связывающих выходные нейроны с единичными входами.

Топология сети выбиралась эмпирически. В большинстве случаев приемлемая архитектура сети содержала два скрытых нейрона. Длина обучающей выборки принималась равной 270 сут, т.е. трем зимним сезонам. Тестирование сети проводилось на оставшейся части данных.

Выбор предикторов. В качестве предикторов были выбраны следующие метеорологические параметры.

1. Суточная норма осадков за предыдущие сутки, Pr_1 .
2. Осадки из массива реанализа в ближайшем узле сетки, Pr_re .
3. Геопотенциал на уровне поверхности 500 мбар в пункте максимального влияния, $H5$.
4. Дивергенция скорости ветра на уровне 850 гПа в пункте максимального влияния, $Div85$.
5. Относительная влажность на том же уровне в пункте максимального влияния, $R5$.

Предиктором служила локальная суточная норма осадков, Pr_0 .

Выбор предикторов диктовался простыми рациональными соображениями. Учитывались: циркуляционная (геопотенциал $H5$) и влажная (относительная влажность $R5$) компоненты; вертикальное движение (горизонтальная дивергенция ветра $Div85$); осадки реанализа Pr_re , являющиеся выходом математической модели, учитывающей влияние многих метеорологических полей; авторегрессионная часть (осадки за предшествующий день Pr_1), отражающая внутренние свойства осадкообразования как случайного процесса. Выбирая в качестве предиктора осадки за предыдущие сутки, мы пытались отразить существенную черту процесса осадкообразования на суточном масштабе: тенденцию сухих и влажных промежутков времени сохраняться более чем на одни сутки [12].

Если последние два предиктора из перечисленных выше представляют собой одномерные временные ряды, то в случае пространственных полей $H5$, $Div85$, $R5$ возникает необходимость их сжатия до разумной размерности, чтобы избежать чрезмерно большого числа входных параметров. Для сжатия размерности полей в данной работе мы использовали концепцию «пункта максимального влияния», состоящую в том, что на входе нейронной сети в

качестве предиктора достаточно выбрать соответствующий метеопараметр в том узле сетки реанализа, в котором он обладает максимальным коэффициентом корреляции с локальными осадками. Этот узел (пункт), вообще говоря, различен для разных метеопараметров.

Композитные карты. Пункты максимального влияния можно найти и другим способом – путем построения композитных карт. Для этого определим типичное барическое поле (пусть это будет поле геопотенциала на уровне поверхности 500 гПа), соответствующее определенному классу метеорологической ситуации. В результате получим так называемую композитную карту, или композит геопотенциала. Проведем разбиение на классы по уровню суточных сумм выпавших осадков, причем в первом приближении можно использовать разбиение на два класса («сухой» и «влажный»), которые соответствуют уровню осадков ниже и выше некоторого порогового значения.

На рис. 2, в приводится пример влажного композита для Николаева в географической рамке 50° з.д. – 120° в.д., 20° – 70° с.ш. Эта рамка включает в себя основные барические центры влияния в Евразийском регионе. Оказалось, что композит поля аномалии геопотенциала в большой степени похож на карту поля корреляции между локальными осадками и полем геопотенциала (рис. 2, а, б).

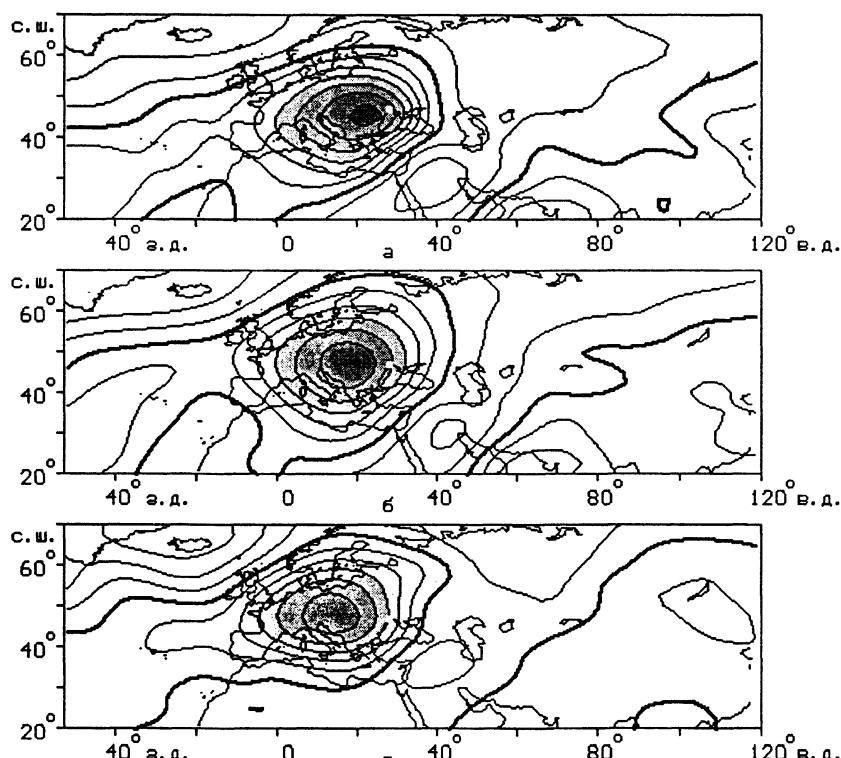


Рис. 2. Карты корреляций между полем аномалии геопотенциала 500 гПа и локальными осадками в Николаеве (а, б) и соответствующая композитная карта (в): а – барическое поле и осадки синхронны; б – опережение барического поля на одни сутки. Интервалы между изолиниями коэффициента корреляции 0,1, изолиниями аномалий – 50 м. Затемненные участки соответствуют положительным величинам

Характерно, что композитной карте лучше, чем синхронная, соответствует карта корреляций при сдвиге на одни сутки. Это можно объяснить следующим образом. Большая часть выборки дневных сумм осадков относится к осадкам малой и средней интенсивности. Для таких осадков барический минимум находится ближе к точке наблюдений и его временное запаздывание составляет менее суток. Композит на рис.2, в построен для большого уровня отсечки по осадкам, т.е. такая барическая аномалия, ответственная за экстремальные осадки, расположена дальше к западу и ее влияние на осадки в пункте наблюдения оказывается одними сутками позже. В связи с этим выбор координаты предикторной переменной в схеме ИНС неоднозначен, он зависит от того, осадки какой интенсивности следует воспроизвести более точно. Для осадков малой интенсивности следует брать синхронный композит, для экстремальных – с заблаговременностью в одни сутки.

Таким образом, местоположение локального минимума в композитной карте, или (что то же самое) местоположение максимума корреляции (синхронно или со сдвигом в одни сутки), идентифицировалось как «пункт максимального влияния», и временной ряд физического параметра в данной точке использовался как один из предикторов в схеме нейронной сети.

Результаты

На рис.3 приводится пример графического сравнения суточных сумм фактических осадков (Николаев) с суммами осадков, моделированных нейронной сетью (рис.3, б) и полученных из реанализа (рис.3, а). Видно, что повторяемость осадков примерно одинаково воспроизводится обеими моделями; различие проявляется в величине их сумм. При этом осадки реанализа по величине существенно ниже.

Рис.4 демонстрирует регрессионную связь тех же данных, что и рис.3, вне интервала обучения нейронной сети, т.е. на независимой выборке. Он содержит 506 точек (длина независимой выборки). Кажущаяся малочисленность точек связана с тем, что примерно две трети из них приходятся на сухие дни, а в этом случае при правильном прогнозе соответствующие точки ложатся в начало координат. Например, дни без осадков, по данным реанализа и наблюдений, в ситуации, соответствующей рис.4, б, в 382 случаях совпадают. Все эти случаи отображаются на графике одной точкой (начало координат).

Как видно, разброс точек по отношению к идеальному прогнозу достаточно велик. Это относится и к нейронной сети, и к реанализу. Для осадков такой разброс не является неожиданным, и, как указывалось, он определяет необходимость совершенствования методики их расчета. Отметим, что другие переменные атмосферы, такие, как температура, давление и т.п., описываются в реанализе существенно лучше.

Несмотря на значительный разброс точек на графике, уравнение регрессии для расчетных точек нейронной сети несколько лучше соответствует наблюдениям. Уровень корреляции на рис. 4, а, б примерно одинаков и составляет 0,5. При таком коэффициенте вклад шумовой составляющей в дисперсию осадков равен ~ 0,75. Он также одинаков для

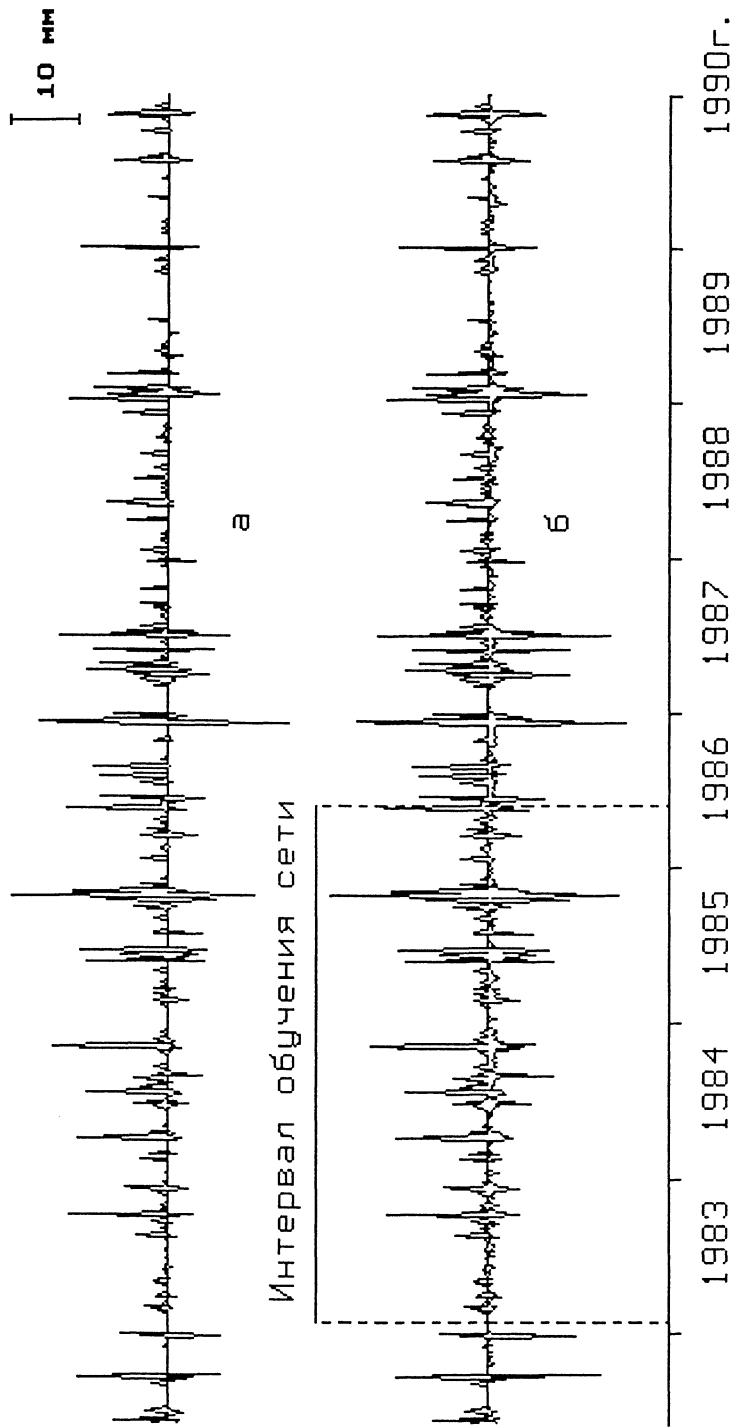


Рис. 3. Сравнение осадков из системы рационализации (а) и моделированных пейронной сетью (б) с фактическими на примере Николаева. Для наглядности модельные осадки отложены по отрицательной оси ординат

осадков из нейронной сети и из системы реанализа. Но при этом на рис. 4, а линия регрессии ложится ближе к идеальной прямой, что говорит о более симметричном разбросе точек относительно средней линии. На рис. 4, б отчетливо видно занижение среднего уровня сумм осадков реанализа по сравнению с фактическими. Это прежде всего должно приводить к систематическому смещению при долговременном осреднении в климатических расчетах.

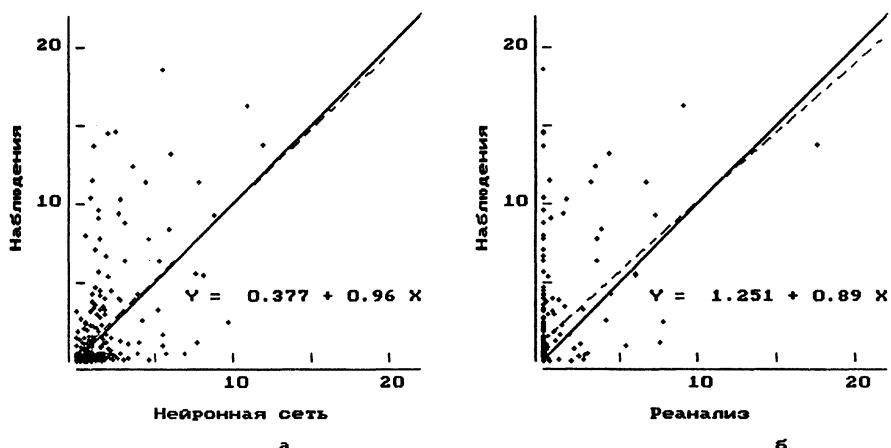


Рис. 4. Корреляция между фактическими осадками в Николаеве и моделями нейронной сетью (а) и системой реанализа (б). Штриховая прямая – линейная регрессия; сплошная, проведенная под углом 45° , соответствует идеальному совпадению между моделью и наблюдениями. Масштаб на осях – в мм

Также видно (рис. 4), что нейронная сеть лучше согласуется с наблюдениями в области умеренных сумм осадков, не превышающих 5 мм, и хуже ведет себя при прогнозировании экстремальных осадков. Это связано с методикой обучения сети и недостаточностью длины обучающей выборки. Из-за небольшого числа экстремальных событий на обучающей выборке они интерпретируются сетью как шум, и для таких событий сеть не способна к обобщению вне интервала обучения.

Однако одного лишь коэффициента корреляции, который определяет линию регрессии, недостаточно для количественной оценки качества моделирования таких существенно негауссовых процессов, как сумма осадков на суточном масштабе. В этом случае для оценки качества моделирования применяются другие количественные критерии.

Критерий качества моделирования. Условимся считать расчетные величины, полученные с помощью ИНС (или из системы реанализа), прогностическими, а из независимой выборки фактических данных, на которой производится тестирование, – наблюдениями. При этих условиях всю совокупность «прогноз плюс наблюдение» можно описать с помощью двумерной матрицы (C -матрицы, согласно принятой в зарубежной литературе терминологии [4]):

$$C = \begin{pmatrix} a & b \\ c & d \end{pmatrix}, \quad (5)$$

где a – число нулей, предсказанных как 0; b – число единиц, предсказанных как 0 (*misses*); c – число нулей, предсказанных как 1 (*false alarm*); d – число единиц, предсказанных как 1 (*hits*), или число корректных значащих прогнозов осадков. Здесь единица и ноль обозначают соответственно события «осадки», «нет осадков».

C-таблица содержит всю необходимую информацию о прогнозе и наблюдении, однако на практике вместо четырех чисел используют скалярные количественные критерии, состоящие из одного числа. За последние 100 лет в метеорологии выработано множество таких критериев [4]. Приведем некоторые из употребительных чисел.

1. Число Хансена – Купера (или индекс эффективности Купера) [13]:

$$HK = \frac{ad - bc}{N_1 N_0}, \quad (6)$$

где N_0 и N_1 – соответственно число ясных дней и дней с осадками. Легко показать, что HK равно 1 в случае идеального прогноза, –1 в случае противоположного и 0 – при случайному или постоянному прогнозах. При этом под постоянным прогнозом понимается постоянное прогнозирование только одного из событий.

2. Смещение (*BIAS*) – отношение числа наблюдаемых дней с осадками к числу прогнозируемых дней:

$$BIAS = N_1 / F_1. \quad (7)$$

Оно характеризует степень идентичности статистики сухих и дождливых дней в наблюдаемом и прогнозируемом процессах.

3. Относительная сумма корректных прогнозов *FRC* (*Fraction Correct*), равная отношению общего числа правильных прогнозов к числу наблюдений:

$$FRC = (a + d) / N. \quad (8)$$

Приведенные числовые показатели рассчитывались как для выхода нейронной сети, так и для данных реанализа. Результаты сравнения содержатся в сводной табл.2. Числа HK , FRC и $BIAS$ рассчитывались при пороговом значении суммы осадков, равном 2 мм. Табл.2 показывает эффективность модели ИНС по совокупности трех рассматриваемых пунктов.

Коэффициент корреляции примерно одинаков для обоих из сравниваемых массивов. Различия наблюдаются по другим критериям. Как следует из табл.2, суммы осадков по данным реанализа существенно занижены по сравнению с фактическими, в то время как осадки с выхода ИНС достаточно адекватно воспроизводят этот показатель.

Обратимся теперь к другим критериям (формулы (6) – (8)). Если по HK и $BIAS$ модель ИНС более адекватна, чем система реанализа, то по FRC данные реанализа лучше согласуются с фактическими, чем воспроизводимые нейронной сетью, хотя отличия незначительны. Это легко объясняется тем, что в числе FRC содержится большая доля «угаданных» сухих дней. Так как (см. табл.1) число сухих дней составляет по всем рассматриваемым городам ~70%, при преобладающем прогнозировании сухих событий прогнозист бу-

деть иметь преимущество. На рис.4 видно, что в системе реанализа прогнозируется избыточное число сухих дней, что нашло отражение и в факторе *BIAS* (табл.2). Критерий *FRC* является сбалансированной оценкой лишь в том случае, когда число сухих дней и дней с осадками примерно одинаково. Этого недостатка лишен индекс эффективности Купера, который не зависит от статистики сухих и дождливых дней [14]. В свете сказанного представляется разумным использовать для оценки степени согласованности между моделью и фактическими данными интегральный критерий, объединяющий оценку прогноза как по непрерывным (средний уровень), так и по дискретным (события «да» – «нет») свойствам осадков.

Т а б л и ц а 2

Числовые показатели качества генерирования осадков нейронной сетью и системой реанализа

Город	Источник данных	ρ	r	<i>FRC</i>	<i>HK</i>	<i>BIAS</i>	<i>S</i>
Николаев	ИНС	1,04	0,51	0,78	0,32	1,22	0,63
	Реанализ	0,31	0,49	0,81	0,21	3,58	0,27
Феодосия	ИНС	0,94	0,49	0,82	0,53	0,79	0,75
	Реанализ	0,66	0,49	0,84	0,50	1,21	0,59
Севастополь	ИНС	0,80	0,47	0,78	0,50	0,75	0,66
	Реанализ	0,32	0,38	0,83	0,32	2,41	0,34

П р и м е ч а н и е. Здесь ρ – отношение средней величины моделюемых осадков к средней величине наблюдаемых осадков; r – коэффициент корреляции между моделюемыми и фактическими осадками; S – из формулы (9).

На этом основании можно предложить следующий критерий S (последний столбец в табл.2):

$$S = \frac{1}{2} \left[HK + \left(1 - \frac{|\bar{o} - \bar{f}|}{\max(\bar{o}, \bar{f})} \right) \right], \quad (9)$$

где \bar{o} и \bar{f} – соответственно средние величины наблюдаемых и прогнозируемых осадков. Очевидно, что в случае идеального прогноза это число принимает значение, равное 1, причем каждое из слагаемых в формуле (9) дает одинаковый вклад, равный 1/2. Из табл.2 следует, что качество моделирования, оцениваемое согласно формуле (9), существенно лучше в случае ИНС по сравнению с данными реанализа.

Наконец, остановимся на случае экстремальных событий, которые условно определим как события, когда за сутки выпадает более 5 мм осадков. В табл.3 приводится число дней, приходящихся на такие события, а также число правильных прогнозов этих событий, согласно данным ИНС и реанализа. Видно, что выбор порога в 5 мм для определения экстремальных осадков оправдан, поскольку события эти достаточно редки. В относительных единицах (по отношению к общему числу рассматриваемых дней) число экстремальных событий составляет 6,1, 6,7 и 10% соответственно для Николаева, Феодосии и Севастополя. Модель ИНС предсказывает экстремальные осадки

значительно лучше, чем реанализ (примерно в два раза улучшается прогнозирование таких событий). Преимущество ИНС здесь достаточно убедительно, хотя и неожиданно, так как обучающая выборка в данном случае содержит очень мало экстремальных случаев. Для более репрезентативного воспроизведения редких экстремальных событий с помощью методики ИНС, безусловно, требуется обучение на более длительном временному интервале.

Таблица 3

Число экстремальных событий (N) и мера успеха (S) в случае, когда суточная сумма осадков превышает 5 мм

Город	N			S		
	1	2	3	1	2	3
Николаев	31	11	6	1,0	0,66	0,24
Феодосия	28	12	5	1,0	0,61	0,42
Севастополь	68	14	6	1,0	0,48	0,21

Причина. Цифры 1, 2 и 3 обозначают соответственно наблюдения, нейронную сеть и реанализ.

Заключение

В результате выполненной работы осуществлена привязка модельных оценок осадков из системы реанализа *NCEP/NCAR* применительно к трем пунктам Украины, примыкающим к Черному морю. Для этого использовались фактические данные по осадкам суточной дискретности и часть массива двухсроковых данных из системы реанализа.

На основе применения метода ИНС была проведена постобработка данных по осадкам из массива реанализа. Результаты применения ИНС показали, что по уровню корреляции между модельными и фактическими осадками нейронная сеть не дает значимого преимущества перед реанализом. Средняя норма осадков воспроизводится нейронной сетью достаточно хорошо, в то время как этот же показатель, согласно данным реанализа, существенно занижен (практически во всех пунктах) по сравнению с данными наблюдений.

Нейронная сеть лучше, чем реанализ, описывает статистику сухих и дождливых дней. Это относится как к точности прогнозирования таких дней по числовому критерию Хансена – Купера, так и к соотношению между общим числом прогнозируемых и наблюдаемых дней с осадками. В работе предложен числовой критерий оценки качества моделирования, суммарно учитывающий указанные выше факторы. По этому критерию данные с выхода ИНС существенно лучше согласуются с наблюдаемыми по сравнению с данными реанализа.

Эффективность нейронной сети оказалась примерно в два раза выше по сравнению с реанализом в прогнозировании редких экстремальных осадков, наиболее значимом в хозяйственной деятельности человека.

Работа показала, что ИНС можно рассматривать как достаточно эффективный метод регионализации оценок осадков глобального реанализа *NCEP/NCAR* применительно к конкретным пунктам. Результатом такого под-

хода являются передаточные функции, или диагностические нелинейные связи между предикторами и локальными осадками. Эти передаточные функции в дальнейшем можно использовать для регионализации выходных данных в модели глобальной изменчивости климата Земли в XXI столетии.

СПИСОК ЛИТЕРАТУРЫ

1. *Proceedings of the International CLIVAR Conference // WMO/TD.* — 1998. — №. 954. — P. 257.
2. *Rosenblatt R. Principles of Neurodynamics.* — New York: Spartan Books, 1959.
3. *Bancert R.L. Cloud classification of AVHRR imagery in maritime regions using a probabilistic neural network // J. Appl. Meteor.* — 1994. — 33. — P. 909–918.
4. *Marzban C., Stumpf G.G. A neural network for damaging wind prediction // Wea. Forecas.* — 1998. — 13, № 3. — P. 151–163.
5. *Klein Tank A.M.G., Coauthors. Daily dataset of the 20th century surface air temperature and precipitation series for the European Climate Assessment // Int. J. Climatol.* — 2002. — 22. — P. 1441–1453.
6. *Ефимов В.В., Порошков В.Л. Статистическое оценивание суточных сумм зимних осадков с использованием метода нейронных сетей // Известия РАН. Физика атмосферы и океана.* — 2003. — 39, № 1. — С. 14–25.
7. *Kalnay E., Coauthors. The NCEP/NCAR 40-Year Reanalysis Project // Bull. Amer. Meteor. Sci.* — 1996. — 77. — P. 437–471.
8. *Katz R.W., Glantz M.H. Anatomy of a rainfall index // Mon. Wea. Rev.* — 1986. — 114. — P. 764–771.
9. *Kuligowski R. J., Barros A.P. Experiments in short-term precipitation forecasting using artificial neural networks// Mon. Wea. Rev.* — 1998. — 126, № 2. — P. 470–482.
10. *Zorita E., Von Storch H. The analog method as a simple statistical downscaling technique: Comparison with more complicated methods // J.Clim.* — 1999. — 12, № 8. — P. 2474–2489.
11. *Rumelhart D.E., Hinton G.E., Williams R.J. Learning representations by back-propagating errors // Nature.* — 1986. — 323. — P. 533–536.
12. *Kuligowski R. J., Barros A.P. Localized precipitation forecasts from numerical weather prediction model using artificial neural networks // Wea. Forecas.* — 1998. — 13, № 12. — P. 1194–1203.
13. *Hansen A.W., Kuipers W.J.A. On the relationship between the frequency of rain and various meteorological parameters // Koninklijk Nederlands Meteorologisch Institut. Meded.Verhand.* — 1965. — 81. — P. 2–15.
14. *Murphy A.H. Scill scores based on the mean square error and their relationships to the correlation coefficient // Mon. Wea. Rev.* — 1988. — P. 2417–2434.

Морской гидрофизический институт НАН Украины,
Севастополь

Материал поступил
в редакцию 20.01.05
После доработки 10.02.05

ABSTRACT Using the data of reanalysis, the data on precipitation with diurnal discreteness are corrected as applied to the observed amount of diurnal precipitation in the concrete geographical points in the Black Sea region. Estimations of the amount of actual precipitation are taken from the European Climate Assessment and Dataset (ECAD). Precipitation of three winter months is analyzed. The method of artificial neural network (ANN) is used as an instrument for investigating the relations between the regular meteorological variables from the reanalysis (predictors) and the local precipitation in a concrete geographical point (predictant). Numerical criterion of adequacy of the estimates of the amount of diurnal precipitation resulted from the reanalysis and the method of artificial neural network is proposed. Application of this criterion shows that, as compared to the reanalysis, the ANN method is more efficient in precipitation modeling.