

РЕГИОНАЛЬНОЕ МОДЕЛИРОВАНИЕ ТЕМПЕРАТУРЫ ПОВЕРХНОСТИ ЧЕРНОГО МОРЯ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

М.В.Шокуров

Морской гидрофизический институт

НАН Украины

г. Севастополь, ул. Капитанская, 2

E-mail: efimov@alpha.mhi.iuf.net

Аннотация

Рассматривается возможность использования аппарата искусственных нейронных сетей для регионального статистического моделирования на примере температуры поверхности Черного моря. Построена трехслойная нейронная сеть с двумя предикторами – температурой воздуха и модулем скорости ветра, и одним предиктантом – температурой воды. Результаты для ежесуточной и еженедельной дискретности качественно одинаковы: нейронная сеть увеличивает объясненную дисперсию по сравнению с линейной регрессией за счет правильного учета существующей слабой нелинейности в зависимости предиктора от предиктандов. Сравнение с результатами других аналогичных исследований приводит к выводу о том, что применение искусственных нейронных сетей является достаточно простым и надежным средством описания многомерных нелинейных связей в полях гидрометеорологических элементов, хотя выбор объектов, где такие связи особенно значимы, а выигрыш от применения значителен, требует тщательного рассмотрения.

1. Введение.

В настоящее время численные модели глобальной атмосферной циркуляции являются наиболее развитым инструментом прогноза погоды, исследования динамических механизмов атмосферной циркуляции на различных временных масштабах, а также реанализа –

анализа состояния атмосферы по имеющимся архивным наблюдениям с помощью современных моделей. Для анализа и прогноза изменчивости климата используются модели совместной циркуляции атмосферы и океана, учитывающие также динамику морского льда и физические процессы на поверхности суши. Эти модели достаточно хорошо воспроизводят основные особенности крупномасштабной циркуляции атмосферы и океана. Однако на малых масштабах глобальные модели неспособны адекватно воспроизвести основные параметры локального климата. Этот недостаток неоднократно отмечался в литературе. Основные причины – недостаточное пространственное разрешение, ограниченное ресурсами вычислительной техники, а также возможно неадекватная параметризация мелкомасштабных подсеточных процессов, таких как формирование облаков, осадки, испарение, речной сток и другие.

Поэтому разработка методов прогноза локальных метеорологических процессов на основе анализа крупномасштабных полей (так называемый downscaling климата) является важной задачей, которая нашла отражение в международной программе исследования изменчивости климата CLIVAR [1]. Одним из основных инструментов для решения этой задачи являются локальные атмосферные модели высокого пространственного разрешения [2]. В то же время гораздо более простыми и дешевыми являются различные методы статистического регионального моделирования, суть которых заключается в определении статистических связей между аномалиями крупномасштабной циркуляции и аномалиями локальных климатических переменных по существующим наблюдениям.

Для некоторых параметров локального климата эти статистические связи достаточно хорошо описываются традиционными линейными регрессионными связями или различными вариантами

канонического корреляционного анализа. Это относится в частности к низкочастотным (внутрисезонным и межгодовым) аномалиям большинства параметров локального климата. Однако на малых (синоптических) временных масштабах связь такого, например, параметра, как осадки, с крупномасштабной циркуляцией плохо описывается линейной регрессией и требует использования других статистических методов.

Одним из таких инструментов являются искусственные нейронные сети. В последнее время они стали широко использоваться для самых различных задач статистического описания регионального климата, для которых линейная корреляция дает плохие результаты. Например, нейронные сети хорошо описывают сильно перемежающийся на синоптических масштабах процесс выпадения осадков [3,4]. Еще один пример – пространственная интерполяция приповерхностной температуры воздуха в регионах со сложным рельефом, которая при использовании искусственных нейронных сетей оказывается лучше традиционных линейных методов интерполяции [5]. Нейронные сети использовались также для построения нелинейных эмпирических ортогональных функций на примере аттрактора Лоренца [6].

В данной работе будет рассмотрен еще один вариант использования нейронной сети: для установления связи температуры поверхности Черного моря с температурой воздуха и скоростью ветра. Для динамического описания температуры поверхности Черного моря необходимы региональная атмосферная модель высокого разрешения, позволяющая рассчитывать поверхностные потоки тепла, и модель циркуляции Черного моря или хотя бы модель верхнего перемешанного слоя для расчета температуры поверхности моря, причем эти модели должны быть связаны, поскольку поверхностные потоки тепла зависят от поверхностной

температуры. Задача статистического ‘даунскейлинга’ представляется гораздо более простой: необходимо установить зависимость температуры поверхности от наиболее значимых крупномасштабных предикторов, например температуры воздуха и скорости ветра, по имеющимся наблюдениям. При этом из-за нелинейности формул для потоков явного и скрытого тепла нейронная сеть должна иметь преимущество перед линейной регрессией.

2. Описание данных.

Были использованы данные реанализа NCEP/NCAR (National Center for Environmental Prediction/National Center of Atmospheric Research, USA) за период 1982-1996гг. Температура воздуха на высоте 2 метра и модуль скорости ветра на высоте 10 метров в этом массиве являются результатом анализа, температура же поверхности моря определялась независимо по спутниковым измерениям. Все три параметра имеют одинаковое разрешение 1.875° по долготе и около 2° по широте. Всего в Черном море находится 12 точек сетки. Дискретность по времени для температуры воздуха и скорости ветра составляет 12 часов, температура воды является кусочно-линейной интерполяцией средненедельных значений с суточной дискретностью.

3. Структура нейронной сети.

Искусственная нейронная сеть (ИНС) представляет собой систему обработки данных, которая позволяет устанавливать соотношение между двумя наборами данных со сколь угодно высокой степенью точности. Она является ‘обучающейся’ системой, позволяющей отображать данные на входе системы в выходные данные при заранее неизвестной нелинейной связи между ними. Практически ИНС является суперпозицией различных функций с фиксированной структурой, состоящей из нескольких слоев

нейронов, осуществляющих нелинейное преобразование входных сигналов в выходные. Достаточно простой универсальной ИНС является система, состоящая из трех слоев нейронов: входного, выходного и промежуточного (скрытого) с произвольным числом нейронов в промежуточном слое. В нашем случае использовалась простая сеть с двумя входами (предикторами) – температурой воздуха $x_1=T_a$ и скоростью ветра $x_2=U$, несколькими n нейронами в скрытом (промежуточном) слое, и одним выходом (предиктантом) – температурой воды T_w (рис. 1). На вход каждого нейрона j скрытого слоя подается линейная комбинация предикторов $y_j = \sum_{i=0}^2 w_{ji}x_i$ с весами w_{ji} , $i=1,2$ и

сдвигами w_{j0} , $j=1,\dots,n$. Для единобразия записи сдвиги включены в набор весов путем добавления постоянного единичного входа $x_0=1$. Связи между нейронами показаны на рис. 1 стрелками. Индекс 1 означает, что набор весов w_{ji} относится к первому слою. Затем каждый нейрон скрытого слоя осуществляет нелинейное преобразование своего входа одной и той же фиксированной функцией $z_j=f(y_j)$, в качестве которой был выбран традиционный гиперболический тангенс $f(y)=\tanh y$. Значение температуры воды на выходе сети определяется как линейная комбинация выходов нейронов скрытого слоя $\tilde{T}_w = \sum_{j=0}^n w_{j2}z_j$ с весами w_{j2} ,

$j=1,\dots,n$ и сдвигом w_{j0} . Как и в первом слое, сдвиг был включен в набор весов путем добавления промежуточного единичного входа $z_0=1$ (рис. 1). Индекс 2 означает, что набор весов w_{j2} относится ко второму слою. Обозначим результирующую суперпозицию функций на выходе сети $\tilde{T}_w=g(\mathbf{x}, \mathbf{W})$, где \mathbf{x} – входной вектор, \mathbf{W} – вектор параметров размерности $4n+1$, содержащий все параметры сети w_{ji} , $j=1,\dots,n$, $i=0,\dots,2$; w_{j0} , $j=0,\dots,n$. Задача оценивания

параметров (обучения сети) ставится как задача минимизация невязки $\varepsilon(\mathbf{W})=\sum_t (T_w(t)-g(\mathbf{x}(t), \mathbf{W}))^2$ по параметрам \mathbf{W} для заданного набора обучающих образов $T_w(t)$, $\mathbf{x}(t)$. Из-за нелинейной зависимости выхода сети g от параметров процедура оценивания является итеративной, однако благодаря послойной организации структуры сети на каждом шаге итераций может быть использован известный метод обратного распространения, упрощающий процедуру оценивания (например [4]). Запишем производную невязки по параметрам сети, пользуясь правилом дифференцирования суперпозиции. Для второго слоя получаем

$$\frac{\partial \varepsilon}{\partial w_j^2} = -2 \sum_t (T_w(t)-g(\mathbf{x}(t), \mathbf{W})) z_j(t)$$

Для первого слоя производная невязки по параметрам равна

$$\frac{\partial \varepsilon}{\partial w_{ji}^1} = -2 w_{ji}^2 \sum_t (T_w(t)-g(\mathbf{x}(t), \mathbf{W})) f'(y_j(t)) x_i(t)$$

где $f'(y)$ есть производная гиперболического тангенса по своему аргументу. В результате итерационная процедура состоит из следующих шагов. Для входного вектора $\mathbf{x}(t)$ и заданных начальных значений параметров \mathbf{W}_0 вычисляются вектора $\mathbf{y}(t)$ и $\mathbf{z}(t)$. Затем вычисляются производные невязки по параметрам по вышеприведенным формулам и приращения параметров за одну итерацию, направленные против градиента невязки в пространстве параметров:

$$\Delta w_{ji}^2 = -\delta \frac{\partial \varepsilon}{\partial w_j^2}, \quad \Delta w_{ji}^1 = -\delta \frac{\partial \varepsilon}{\partial w_{ji}^1}$$

где δ – некоторое достаточно малое число. Процедура останавливается, когда невязка перестает уменьшаться с увеличением числа итераций.

Не останавливаясь на всех особенностях и ограничениях анализа с помощью ИНС, достаточно подробно освещенных в литературе, отметим

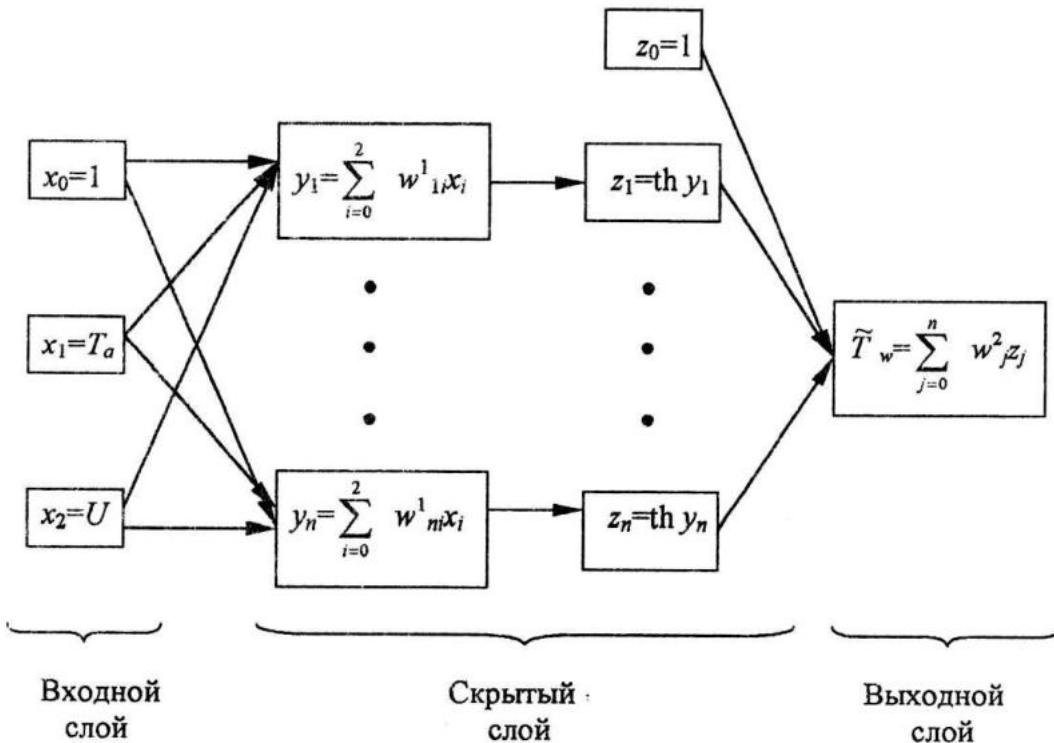


Рис. 1. Структура нейронной сети с двумя нейронами во входном слое, n нейронами в скрытом слое и одним нейроном в выходном слое. Связи между нейронами обозначены стрелками. Вспомогательные нейроны $x_0=1$ и $z_0=1$ добавлены для удобства записи формул.

лишь некоторые. Выбор количества нейронов в скрытом слое трудно сделать заранее, поэтому он определяется перебором и сравнением полученных результатов. Еще одна проблема связана с вопросом о глобальности полученного в итеративной процедуре минимума невязки. Различные начальные (затравочные) значения параметров могут привести к различным локальным минимумам невязки. Рекомендуется оценивать параметры несколько раз с различными случайно выбранными затравочными значениями параметров и затем выбирать минимальный из полученных минимумов невязки [7]. Кроме того, не рекомендуется делать большого количества итераций, потому что для достаточно большого количества параметров при увеличении числа итераций сеть начинает обучаться шуму, содержащемуся в предъявляемых образах. При оценивании параметров обычной регрессии для устранения

влияния шума на результат статистически незначимые параметры отбрасываются, в случае нейронной сети для этой цели из-за трудности оценивания значимости параметров предпочитают обрывать процедуру обучения на малом числе итераций [7]. На качественном уровне можно сказать, что искусственная нейронная сеть должна работать так же, как и реальные нейронные сети: усвоение предъявляемой в обучающих образах информации должно происходить быстро хотя и в ущерб качеству запоминания (оптимальности невязки).

4. Результаты.

Нейронная сеть с двумя предикторами – температурой воздуха и модулем скорости ветра, и одним предиктантом – температурой воды, была построена по данным реанализа NCEP/NCAR за период 1982-1996гг для Черного моря. Далее будут приведены результаты для

	Ежесуточные данные	Еженедельные данные
$\langle T_a \rangle$ (°C)	13.16	13.16
$\langle U \rangle$ (м/с)	5.17	5.17
$\langle T_w \rangle$ (°C)	14.71	14.71
σ_{T_a} (°C)	6.94	6.82
σ_U (м/с)	2.07	1.42
σ_{T_w} (°C)	6.38	6.38
$r(T_a, T_w)$	0.944	0.960
$r(U, T_w)$	-0.352	-0.514
$r(T_a, U)$	-0.421	-0.621
α_{T_a}	0.968	1.043
α_U	0.055	0.134
$\sigma_{T_w \text{ объясн}}^2$ (регрессия)	89.4%	93.3%
$\sigma_{T_w \text{ объясн}}^2$ (сеть, $n=1$)	92.1%	94.7%
$\sigma_{T_w \text{ объясн}}^2$ (сеть, $n=2$)	92.1%	94.7%
$\sigma_{T_w \text{ объясн}}^2$ (сеть, $n=3$)	92.1%	94.8%
$\sigma_{T_w \text{ объясн}}^2$ (сеть, $n=4$)	92.1%	94.8%

Табл.1. Параметры исходных данных, линейной регрессии и нейронных сетей для данных с суточной и недельной дискретностью. σ – среднеквадратичные величины, r – коэффициенты корреляции, α – коэффициенты регрессии для нормированных величин, $\sigma_{\text{объясн}}^2$ – объясняемые дисперсии в % (описываемые регрессией или нелинейной зависимостью).

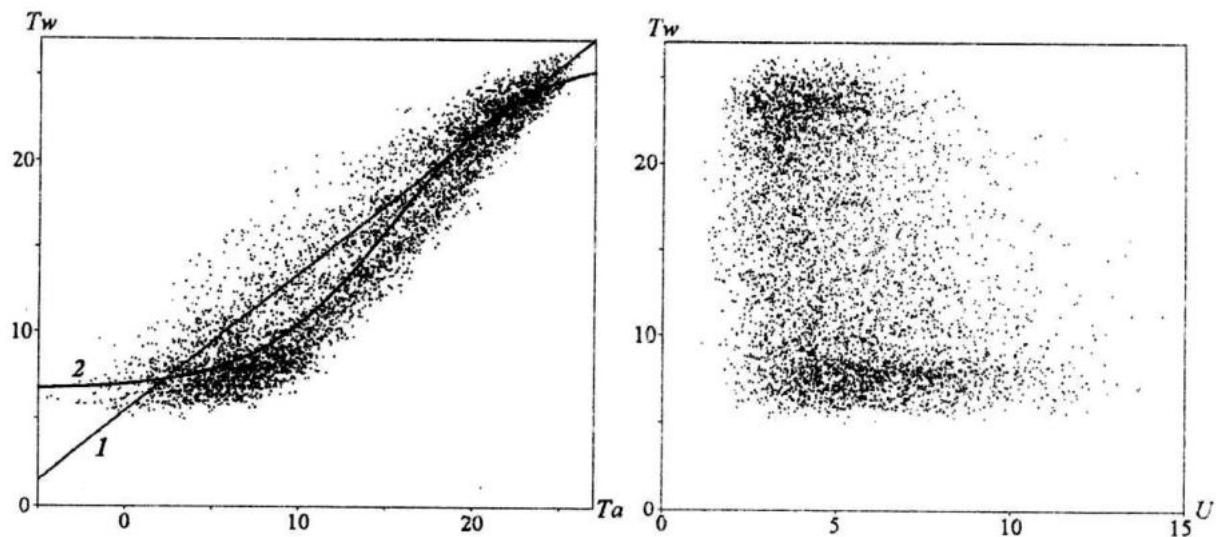


Рис. 2. Зависимость температуры воды от температуры воздуха (слева) и от модуля скорости ветра (справа). На левом фрагменте приведены также график линейной регрессии (1) и нелинейной зависимости, определяемой нейронной сетью (2) при $U=0$.

средних по всему морю значений параметров, поскольку результаты для отдельных квадратов отличаются не принципиально. Было выполнено построение нейронной сети для двух вариантов временных рядов на входах и выходе сети: исходные данные с суточной и с недельной дискретностью.

В качестве предварительного этапа была построена стандартная линейная регрессия температуры воды на температуру воздуха и модуль скорости ветра. Облако точек в проекциях на плоскости (T_a, T_w) и (U, T_w) приведено на рис.2 для суточной дискретности. Результаты линейной регрессии – средние, дисперсии, коэффициенты корреляции и регрессии, а также объясненные дисперсии – представлены в таблице 1. Корреляции температуры воды и воздуха очень высоки, и поэтому линейная регрессия объясняет 89.4% и 93.3% дисперсии температуры воды соответственно для суточной и недельной дискретности. Вклад скорости ветра в объясненную дисперсию очень мал, хотя корреляция температуры воды и ветра значительна. Это связано с тем, что предикторы – температура воздуха и ветер – коррелированы и при построении регрессии ветер эффективно исключается.

Нейронная сеть с одним нейроном в промежуточном слое описывает имеющуюся в данных слабую нелинейность зависимости температуры воды от температуры воздуха и увеличивает объясненную дисперсию соответственно до 92.1% и 94.7% для данных с суточной и недельной дискретностью (табл.1). Как видно, увеличение объясненной дисперсии по сравнению с линейной регрессией в целом незначительно и составляет 1-2% в обоих случаях, однако нейронная сеть существенно лучше описывает корреляционное облако точек в той области, где зависимость $T_w(T_a)$ и $\Delta T_w(\Delta T_a)$ значительно отличается от линейной. Это явно видно для области

малых T_w и T_a : для малых и даже отрицательных величин температуры воздуха температура воды в Черном море не понижается ниже 5-6°C. Для иллюстрации механизма уменьшения остаточной дисперсии на рис. 2 приведены графики зависимости $T_w(T_a)$ для нулевой скорости ветра для линейной регрессии и для нейронной сети с одним нейроном в промежуточном слое. Из рисунка видно, что нейронная сеть правильно схватывает имеющуюся в облаке точек кривизну и таким образом уменьшает остаточную дисперсию. Увеличение количества нейронов в скрытом слое от 1 до 4 (табл.1) и дальше (не показано) влияет на объясненную дисперсию незначительно.

Поскольку в рассматриваемых случаях количество параметров сети (19 для $n=4$) значительно меньше количества обучающих образов (5479 и 782 для суточной и недельной дискретности), незначительный выигрыш от применения нейронной сети к объяснению полной дисперсии величины T_w в зависимости от T_a и U свидетельствует об отсутствии значительных скрытых нелинейных связей во всем диапазоне изменений T_w , которые не может описать линейная регрессия и которые могла бы выявить нейронная сеть. Вклад же областей изменчивости T_w , где нелинейность связи с T_a и U существенна, в суммарную дисперсию температуры воды невелик.

В рассматривавшихся ранее в литературе немногочисленных примерах использования нейронных сетей для моделирования различных гидрометеорологических параметров такого рода связи как правило очевидны заранее. В случае моделирования суточных норм осадков, например [3], основное достоинство нейронной сети состоит в ‘нелинейном выпрямлении’ входов, имеющих гауссовское распределение вероятностей, в выход, имеющий несимметричное одностороннее распределение вероятностей. В случае постро-

ения нелинейных эмпирических ортогональных функций с помощью нейронных сетей на примере аттрактора Лоренца [6] ‘кривизна’ аттрактора и преимущество нелинейных ЭОФ также очевидны заранее. Результат нашей работы свидетельствует о том, что применение искусственных нейронных сетей является достаточно простым и надежным средством описания многомерных нелинейных связей в полях гидрометеорологических элементов, хотя выбор объектов, где такие связи особенно значимы, а выигрыш от применения значителен, требует тщательного рассмотрения.

ЛИТЕРАТУРА

1. CLIVAR. A study of climate variability and predictability. Science plan. August 1995, WCRP-89, WMO/TD No. 690, 157p.
2. Cubasch U., von Storch H., Waszkewitz J., Zorita E. Estimates of climate change in Southern Europe derived from dynamical climate model output. *Climate Research*, 1996, v7, N2, November 29, 129-149.
3. Zorita E., von Storch H. The analog method as a simple statistical downscaling technique: comparison with more complicated methods. *J.Climate*, 1999, v12, 2474-2488.
4. Hsu K.L., Gao X. Sorooshian, Gupta H.V. Precipitation estimation from remotely sensed information using artificial neural networks. *J Applied Meteorology*, 1997, v36, 1176-1184.
5. Snell S.E., Gopal S., Kaufmann R.K. Spatial interpolation of surface air temperature using artificial neural networks: Evaluating their use for downscaling GCMs. *J.Climate*, 2000, v13, 886-895.

6. Monahan A.H. Nonlinear principal component analysis by neural networks: Theory and application to the Lorenz system. *J.Climate*, 2000, v13, 821-835.

7. Hsieh W.W., Tang B. Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin AMS*, 1998, v79, 1855-1870.

REGIONAL MODELING OF THE BLACK SEA SURFACE TEMPERATURE USING ARTIFICIAL NEURAL NETWORKS

M.V.Shokurov

Abstract

Possibility of applying of the artificial neural networks for the regional statistical modelling is considered with the Black Sea surface temperature as an example. Three-layer neural network including two predictors – air temperature and wind speed, and one predictand – sea surface temperature, is constructed. Results for the raw data and anomalies relative to annual cycle for the daily and weekly time steps are qualitatively similar: neural network enhances the explained variance by 1-2% in comparison with the linear regression due to correct account of existing weak nonlinearity in the dependence of predictand on the predictors. Comparison of our results with the results of another similar studies infers that applying of artificial neural networks is rather simple and reliable instrument for the description of multidimensional nonlinear relations in the hydrometeorological fields, although the selection of subject of inquiry, where such relations are pronounced features, and advantage of neural networks applying is significant, needs subtle consideration.