

К ВОПРОСУ ПРОГНОЗИРОВАНИЯ ТЕМПЕРАТУРЫ ВОЗДУХА НА ПРИМЕРЕ БЕЛАРУСИ

Введение. Проблемы анализа и прогноза изменений температуры воздуха, а также исследование возможных последствий этих изменений в различных областях человеческой деятельности в последние годы приняли острый характер. Связано это с тем, что изменения температуры воздуха могут привести к трансформации термического и гидрологического режимов обширных территорий земного шара, что может оказать значительное влияние на социально-экономическую и политическую ситуацию в масштабах не только отдельной страны, но и всей планеты. С 1988 г. на территории Беларуси начался очередной период потепления, который характеризуется резким повышением температуры зимой и не имеет себе равных по продолжительности и интенсивности за весь период метеонаблюдений в Беларуси [4]. Сложно предсказать, какие тенденции в изменении температуры воздуха ожидаются в ближайшие десятилетия, но следует отметить, что начавшееся в конце XX столетия на территории Беларуси потепление продолжится в настоящее время, и в связи с этим получение прогнозных оценок изменения температуры воздуха требует постоянного изучения и уточнения.

Целью данной работы является оценка возможности применения аддитивной модели и искусственных нейронных сетей при прогнозировании временных рядов значений среднемесячных температур воздуха.

Исходные данные. В данной работе использованы метеорологические данные Государственного учреждения «Республиканский центр по гидрометеорологии, контролю радиоактивного загрязнения и мониторингу окружающей среды» Министерства природных ресурсов и охраны окружающей среды Республики Беларусь за период с 1978 по 2016 г.

Используемые методы прогнозирования. Прогнозирование является процессом предопределения и выявления возможных вариантов будущего развития на основании исходных параметров (закономерностей, тенденций, связей, опыта и т. п.). Существуют различные методы для прогнозирования температур воздуха, но в полном объеме ни один метод не обеспечивает пока требуемой точности прогноза. При этом выбор тех или иных методов зависит как от области их применения, так и от поставленных целей проводимых прогнозных исследований, а также от доступности для исследователя конкретных инструментов прогнозирования.

Один из методов вероятностно-статистического аппарата, который используется для прогнозирования показателей температуры воздуха, является построение аддитивной модели временного ряда. Под временным рядом подразумевается совокупность значений статистического показателя, расположенных в хронологической последовательности и характеризующих изменение каких-либо явлений во времени [3]. Целью анализа временных рядов является прогноз значения некоторой переменной в определенный момент времени по значениям в предшествующие моменты времени.

Сущность процедуры анализа временных рядов заключается в выявлении структурных составляющих временного ряда для построения аддитивной модели ряда и использовании этих знаний для предсказания его поведения в будущем. Для реализации этой процедуры необходимо проанализировать исходную структуру временного ряда и выявить её закономерность; разложить временной ряд на его составляющие: трендовую, сезонную и случайную компоненты.

Анализ исходной структуры ряда. Рассмотрим многолетний ход среднегодовых температур воздуха Беларуси за 1978–2017 гг.

Волчек Александр Александрович, д. геогр. н., профессор, декан факультета инженерных систем и экологии Брестского государственного технического университета, e-mail: volchak@tut.by.

Сидак Светлана Васильевна, магистр физ.-мат. н., ассистент кафедры информатики и прикладной математики Брестского государственного технического университета.

Беларусь, БрГТУ, 224017, г. Брест, ул. Московская, 267.




Рисунок 1 – Многолетний ход среднегодовых температур воздуха в Беларуси

Из рисунка 1 видно, что за исследуемый период наблюдается положительный тренд роста среднегодовой температуры, который составил 0,53 °C/10 лет.

Проведем анализ временных рядов многолетних значений температур воздуха по месяцам. В таблице 1 приведены результаты такого анализа.

Таблица 1 – Анализ временных рядов многолетних значений температур

месяц	среднее, °C	стандартное отклонение	дисперсия	асимметрия	эксцесс
Январь	-4,71	3,57	12,76	-0,97	1,32
Февраль	-4,23	3,97	15,75	-0,30	-0,23
Март	0,49	2,76	7,63	-0,36	0,00
Апрель	7,50	1,69	2,86	-0,29	-0,20
Май	13,55	1,73	3,00	-0,45	0,33
Июнь	16,69	1,48	2,18	0,57	0,14
Июль	18,54	1,79	3,22	0,28	-0,09
Август	17,58	1,34	1,80	0,16	0,24
Сентябрь	12,46	1,45	2,11	-0,48	-0,44
Октябрь	6,84	1,32	1,73	-0,25	-0,73
Ноябрь	1,30	2,51	6,31	-0,91	1,25
Декабрь	-2,86	2,96	8,77	-0,53	-0,01

Из представленной таблицы видно, что максимальное среднее квадратическое отклонение приходится на январь (3,57°C) и февраль (3,97°C).

Построение аддитивной модели временного ряда. Общий вид аддитивной модели ряда следующий:

$$Y = T + S + E. \quad (1)$$

Так, по аддитивной модели, каждый уровень временного ряда представляет собой сумму трендовой (T), сезонной (S) и случайной (E) компонент.

Для расчета компонентов аддитивной модели (1) временного ряда проводится выравнивание исходных уровней ряда методом скользящей средней. Для этого:

1) уровни ряда суммируются последовательно за каждый год со сдвигом на один месяц и определяются условные годовые объемы температуры воздуха;

2) разделив полученные суммы на 12, находятся скользящие средние. Отметим, что полученные таким образом выровненные значения уже не содержат сезонной компоненты;

3) эти значения приводятся в соответствие с фактическими моментами времени, для чего находятся средние значения из двух последовательных скользящих средних – центрированные скользящие средние.

Для расчета значений сезонной компоненты S_i используются оценки сезонной компоненты. Они рассчитываются как разность между фактическими уровнями ряда и центрированными скользящими средними. Для этого по каждому году находятся средние за каждый месяц оценки сезонной компоненты S_i . В моделях с сезонной компонентой обычно предполагается, что сезонные воздействия за период взаимопогашаются, что выражается в равной нулю сумме значений сезонной компоненты по всем месяцам.

Для того чтобы исключить влияние сезонной компоненты, вычтем ее значение из каждого уровня исходного временного ряда. При этом получим величины $T + E = Y - S$. Эти значения рассчитываются за каждый момент времени и содержат только тенденцию и случайную компоненту.

Далее определяется компонента T данной модели. Для этого проводится аналитическое выравнивание ряда $(T + E)$ с помощью линейного тренда. В результате получается уравнение вида:

$$T = a + b \times t. \quad (2)$$

Подставляя в уравнение (1) значения $t = 1, \dots, N$, находятся уровни T для каждого момента времени.

Прогнозное значение F_t уровня временного ряда в аддитивной модели есть сумма трендовой и сезонной компонент.

$$F = T + S_i \quad (i = \overline{1, 12}). \quad (3)$$

Прогнозирование данных методом искусственных нейронных сетей. Искусственные нейронные сети (ИНС) – мощный метод статистического моделирования, который позволяет воспроизводить весьма сложные зависимости. ИНС представляет собой систему соединенных и взаимодействующих между собой узлов искусственной нейронной сети, именуемых также искусственными нейронами (нейронными клетками, формальными нейронами), которые представляют собой элементарные процессоры и являются упрощенными моделями биологических нейронов. В теории ИНС нейрон – это система отображения из n -мерного пространства входов, формируемого сигналами с выходов других нейронов, либо внешней средой, в одномерное пространство (скалярный сигнал) на выходе нейронной клетки [1, с. 3]. У каждого нейрона имеются входы, через которые происходит прием сигналов. Поступившие на входы сигналы X_j умножаются на свои веса w_j . На каждом входе получаем произведения вида $X_j w_j$. Затем все произведения передаются в сумматор. Результатом работы сумматора является число, называемое взвешенной суммой (net):

$$net = \sum_{i=1}^n x_i w_i. \quad (4)$$

Функция активации служит для преобразования взвешенной суммы net в число, которое является выходом нейрона. Модель искусственного нейрона представлена на рисунке 2.

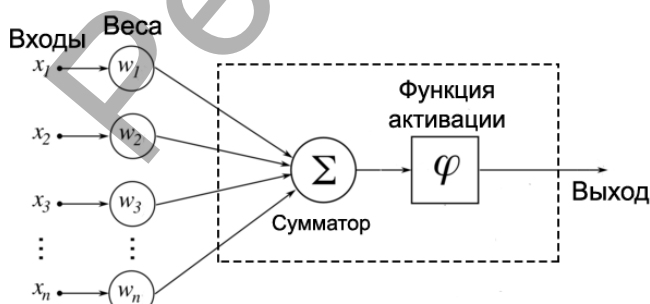


Рисунок 2 – Модель искусственного нейрона

Процесс прогнозирования с помощью нейронных сетей состоит из нескольких основных этапов, которые представлены на рисунке 3.



Рисунок 3 – Блок-схема процессов моделирования ИНС

Рассмотрим подробнее некоторые из этих этапов.

Задание контрольной и обучающей выборки. Для оценки качества полученной модели необходимо проверить её на наборе данных, который не использовался для обучения. После того, как исходные данные подготовлены, их необходимо разделить на множества. Как правило, выделяют два множества: обучающее и тестовое. Реже выделяют третье множество – проверочное. На данный момент не существует универсальных правил для определения размеров этих множеств. В большинстве случаев обучающее множество содержит 70% от всего объема данных, проверочное – 20% и тестовое – 10%. Иногда, анализируя результаты работы нейронной сети, проводится перераспределение процентного соотношения между выборками.

Выбор архитектуры нейронной сети. Выбор архитектуры сети – важный элемент работы с ИНС. Архитектура сети – это способ связи и организации отдельных элементов нейронной сети (нейронов). К сожалению, теоретических предпосылок, говорящих о том, какую топологию нейронной сети стоит использовать для решения той или иной задачи нет. Наиболее часто используемая архитектура сети – многослойный перцептрон (МП). Сеть типа многослойного перцептрона может моделировать функцию практически любой степени сложности, причем число слоев и число элементов в каждом слое определяют сложность функции. Пример многослойного перцептрона представлен на рисунке 4.




Рисунок 4 – Многослойный перцептрон с двумя скрытыми слоями

Для решения научных задач широкое применение также находит использование архитектуры радиальных базисных функций (РБФ) для построения ИНС. Преимущества РБФ по сравнению с МП: 1) моделирование произвольной нелинейной функции с помощью

Index	Net. name	Training perf.	Test perf.	Validation perf.	Training error	Test error	Validation error	Training algorithm	Error function	Hidden activation	Output activation
6	MLP 12-10-1	0.964078	0.961933		2.723656	2.548660		BFGS 21	SOS	Logistic	Identity
7	MLP 12-1-1	0.962438	0.961611		2.845335	2.546430		BFGS 20	SOS	Tanh	Identity
8	MLP 12-10-1	0.964486	0.961933		2.694087	2.536818		BFGS 20	SOS	Logistic	Identity
9	MLP 12-1-1	0.961690	0.961825		2.904099	2.549429		BFGS 10	SOS	Tanh	Identity
10	MLP 12-3-1	0.963196	0.961821		2.789116	2.544242		BFGS 19	SOS	Logistic	Identity

Рисунок 6 – Описание сети

всего лишь одного промежуточного слоя (что избавляет от поиска оптимального количества промежуточных слоев); 2) сеть РБФ обучается быстрее МП.

Обучение нейронной сети. Нейронные сети не программируются, они обучаются. Для решения какой-либо задачи на компьютере традиционным методом необходимо знать правила (математические формулы), по которым из входных данных можно получить выходные (найти решение задачи). С помощью нейросети можно найти решение, не зная правил, а имея несколько примеров. Цель обучения – минимизировать функцию ошибки, то есть найти такие значения параметров сети, при которых текущие выходные сигналы сети минимально отличаются от соответствующих желаемых выходных сигналов, заданных обучающей выборкой. В ходе обучения нейронная сеть способна выявлять сложные зависимости между входными и выходными данными, а также выполнять обобщение. Обычно полагается, что процесс обучения имеет перманентный характер, и с течением времени сеть улучшает свои характеристики, постепенно «приближаясь» к оптимальному решению поставленной задачи [1, с. 33]. Технически обучение заключается в поиске коэффициентов связей между нейронами.

Для обучения ИНС, как правило, применяется метод обратного распространения ошибок, заключающийся в том, что при подаче на вход сети обучающих данных сравнивается выход сети с действительным значением, и затем синаптические веса каждого нейрона корректируются пропорционально тому вкладу, что они внесли в формирование выходной величины, начиная от выходных нейронов к входным.

Выбор наилучшей сети:

После процесса обучения сети необходимо выбрать наилучшую сеть:

- 1) анализируем производительность сети (лучшая сеть будет иметь наибольшую производительность);
- 2) смотрим на распределение остатков (лучшая сеть будет иметь нормальное распределение остатков);
- 3) необходимо визуально посмотреть, насколько хорошо наши построенные сети прогнозируют исходный ряд.

Рассмотрим алгоритм реализации нейросетевой модели с помощью инструментальных средств – пакета Statistika 13.

Задаем условие на использование переменных. Всего у нас наблюдений 468, поэтому будем использовать наблюдения от 1 до 456, а остальные 12 оставим для кросс-проверки.

Задаем размеры подвыборки: обучающая – 70%, контрольная – 30%, на тестовую отводим 0%, т. к. последние 12 наблюдений используются в качестве теста (рисунок 5).

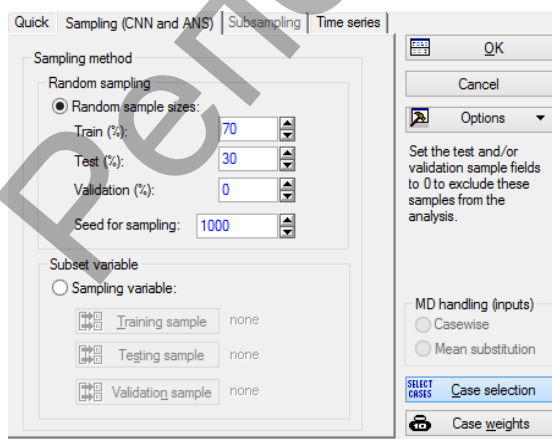


Рисунок 5 – Задание размеров выборок

Задаем параметры сети:

- тип сети (MLP или RBF);
- минимальное количество скрытых нейронов;
- максимальное количество скрытых нейронов;
- количество сетей для обучения;
- количество сетей для сохранения.

После проведения обучения сети следует обратить внимание на описание сетей, представленное на рисунке 6.

Описание сети включает следующую информацию: архитектуру сети (MLPN1-N2-N3, N1- количество входов, N2 – количество скрытых нейронов, N3 – количество выходов), производительность (характеризуется величиной корреляции между исходным рядом и предсказанным на каждой подвыборке), численное значение ошибки обучения (Training error), алгоритм обучения и итерация, на которой этот алгоритм остановлен (training algorithm), функция ошибки и функция активации.

Возможно построение гистограммы распределения остатков для каждой сети как для обучающей, так и для контрольной выборки (рисунок 7). Показателем хорошего качества построенных моделей является нормальное распределение остатков.

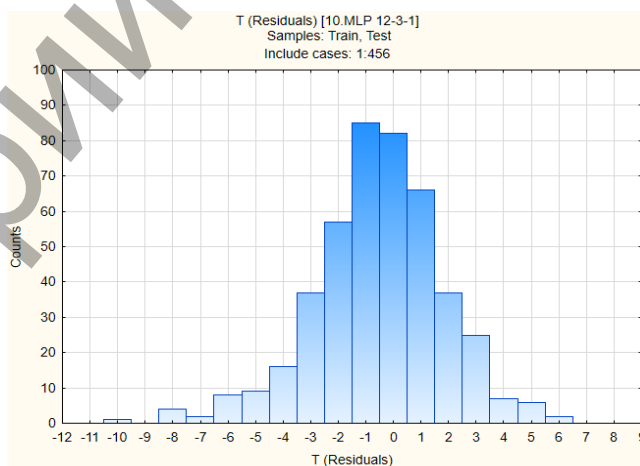


Рисунок 7 – Гистограмма распределения остатков

После этого этапа можно убрать из рассмотрения сети, у которых низкая производительность и распределение остатков не приближено к нормальному.

Для визуальной оценки адекватности моделей прогноза относительно фактического ряда температур воздуха построен график временного ряда (рисунок 8).

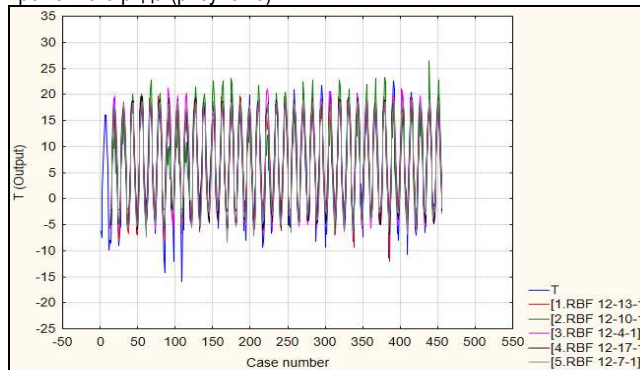


Рисунок 8 – График временного ряда

Результаты прогнозирования температуры воздуха. Все описанные выше процедуры расчёта и анализа данных по аддитивной модели полностью автоматизированы в программе MO Excel+VBA. Для каждой выборки вычислены показатели эффективности расчетов (EFF) и модуль систематической ошибки (Bias):

$$EFF = 1 - \frac{\sum (x_{sim} - x_{obs})^2}{\sum (x_{obs} - x_{obs})^2}; \quad (5)$$

$$Bias = 1 - \frac{\sum (x_{sim} - x_{obs})}{\sum x_{obs}} \cdot 100\%. \quad (6)$$

В зависимости от длительности базового периода величины EFF и Bias меняются: EFF возрастает с увеличением базового периода, а величина ошибки Bias снижается (таблица 2).

Таблица 2 – Изменение показателей EFF и Bias

Базовый период	Прогноз на 12 мес.		Прогноз на 36 мес.	
	EFF	Bias	EFF	Bias
1978-2013	0,95	14%	0,934	17%
1988-2013	0,95	15%	0,933	17,6%
1998-2013	0,94	15%	0,923	18,6%

На рис. 9 представлены результаты прогнозирования температуры на 2009 г. (в качестве исходных данных – температура за 1978-2008 гг.), на рис. 10 – результаты прогнозирования на 2014–2016 гг. (в качестве исходных данных – температура за 1978–2013 гг.), соответственно.

№ месяца	Трендовая компонента	Случайная компонента	Прогнозируемое значение	Фактическое значение	(прогн-факт)^2	(факт-факт_средн)^2
Январь 2009	7,7141	-11,1151	-3,4010	-3,9783	0,3333	124,8359
Февраль 2009	7,7194	-11,1213	-3,4020	-3,1896	0,0451	107,8323
Март 2009	7,7246	-6,5738	1,1508	0,5239	0,3900	44,4993
Апрель 2009	7,7299	0,5752	8,3051	8,6839	0,1435	2,2178
Май 2009	7,7351	6,6429	14,3780	12,8038	2,4783	31,4620
Июнь 2009	7,7404	9,8118	17,5522	16,2657	1,6549	82,2844
Июль 2009	7,7457	11,5235	19,2692	18,6890	0,3965	132,1209
Август 2009	7,7509	10,5824	18,3333	16,3151	4,0731	88,1833
Сентябрь 2009	7,7562	5,4638	13,2200	14,1069	0,7865	47,7786
Октябрь 2009	7,7614	0,1662	7,9276	6,0754	3,4310	1,2528
Ноябрь 2009	7,7667	-5,9816	1,7851	3,7490	3,8568	11,8723
Декабрь 2009	7,7720	-9,9739	-2,2020	-3,7089	2,2709	118,8877




Рисунок 9 – Прогнозирование температуры на 2009 год

В таблице 3 приведены результаты прогнозирования температуры воздуха с помощью ИНС на 2014 год. В качестве базового периода использованы температуры с 1978 г. по 2013 г.

Таблица 3 – Прогнозные значения температур на 2014 г.

№ месяца	Фактическое значение	Прогнозируемое значение	Факт.- прогн. значение
Январь 2014	-6,4182	-4,8633	-1,5549
Февраль 2014	-0,3234	-3,7507	3,4273
Март 2014	5,2828	1,1750	4,1078
Апрель 2014	8,7873	8,5743	0,2130
Май 2014	14,8404	13,6773	1,1630
Июнь 2014	15,5765	16,0822	-0,5056
Июль 2014	20,4487	20,9698	-0,5211
Август 2014	18,7393	17,8926	0,8466
Сентябрь 2014	13,3577	12,7467	0,6110
Октябрь 2014	6,6121	7,4862	-0,8740
Ноябрь 2014	1,3476	0,8573	0,4902
Декабрь 2014	-2,3583	-2,8274	0,4690

В таблице 4 приведены параметры архитектур некоторых используемых нами ИНС.

№ месяца	Трендовая компонента	Случайная компонента	Прогнозируемое значение	Фактическое значение	(прогн-факт)^2	(факт-факт_средн)^2
Январь 2014	7,7143	-11,4368	-3,7224	-6,4182	7,2671	211,5284
Февраль 2014	7,7185	-11,3647	-3,6461	-0,3235	11,0402	71,3903
Март 2014	7,7227	-6,7616	0,9611	5,2829	18,6779	8,0823
Апрель 2014	7,7269	0,6488	8,3757	8,7873	0,1694	0,4376
Май 2014	7,7311	6,7653	14,4964	14,8405	0,1184	45,0866
Июнь 2014	7,7353	9,9027	17,6380	15,5766	4,2495	55,5140
Июль 2014	7,7396	11,6979	19,4374	20,4487	1,0227	151,8540
Август 2014	7,7438	10,6276	18,3714	18,7393	0,1354	112,6465
Сентябрь 2014	7,7480	5,5217	13,2697	13,3577	0,0078	27,3279
Октябрь 2014	7,7522	0,0911	7,8433	6,6121	1,5159	2,2913
Ноябрь 2014	7,7564	-5,6654	2,0910	1,3476	0,5526	45,9441
Декабрь 2014	7,7606	-10,0266	-2,2660	-2,3583	0,0085	109,9179
Январь 2015	7,7648	-11,4368	-3,6720	-1,1007	6,6111	85,1294
Февраль 2015	7,7690	-11,3647	-3,5956	-0,8173	7,7190	79,9800
Март 2015	7,7732	-6,7616	1,0116	4,2610	10,5590	14,9366
Апрель 2015	7,7774	0,6488	8,4262	7,6570	0,5917	0,2198
Май 2015	7,7816	6,7653	14,5469	12,7894	3,0886	21,7495
Июнь 2015	7,7858	9,9027	17,6685	16,6381	1,1033	72,4569
Июль 2015	7,7900	11,6979	19,4879	18,4794	1,0171	107,1993
Август 2015	7,7942	10,6276	18,4219	19,8103	1,9277	136,5272
Сентябрь 2015	7,7985	5,5217	13,3202	14,8569	2,3615	45,3074
Октябрь 2015	7,8027	0,0911	7,8938	5,5357	5,5608	6,7088

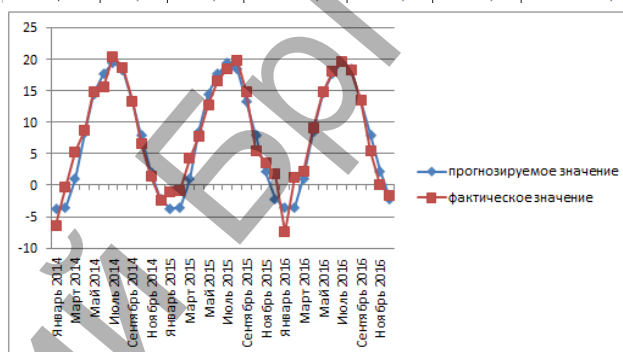


Рисунок 10 – Прогнозирование температуры на 2014–2016 гг.

Таблица 4 – Параметры архитектур используемых ИНС

Архитектура сети	Минимальное количество скрытых нейронов	Максимальное количество скрытых нейронов	EFF
МП-1	1	1	0,91653
МП-2	1	10	0,92108
МП-3	2	8	0,90610
РБФ-1	1	20	0,94402
РБФ-2	1	30	0,94728
РБФ-3	3	20	0,94130
РБФ-4	3	60	0,93668
РБФ-5	4	25	0,95809
РБФ-6	5	30	0,94283

На рисунке 11 показаны ошибки прогнозирования температуры воздуха по месяцам.

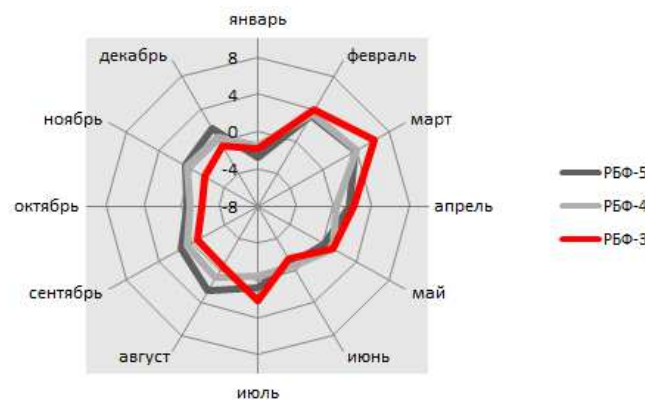


Рисунок 11 – Распределение ошибок прогнозирования по месяцам

Из рисунка 11 видно, что наибольшие по величине ошибки прогнозирования наблюдаются в феврале и марте, что связано с максимальной временной изменчивостью температуры воздуха в эти месяцы.

Заключение. В статье исследована возможность применения методов анализа временных рядов путем построения аддитивной модели и использования ИНС при прогнозировании температуры воздуха. Проанализировав результаты прогноза, полученные двумя предложенными методами, приходим к следующему выводу: представленные в работе способы построения прогностической модели достаточно просты, наглядны и весьма эффективны. В двух используемых методах прогнозирования показатели эффективности прогноза $EFF > 0.9$ (достаточно хорошие). Самый высокий показатель EFF достигается при использовании ИНС (архитектуры РБФ-5). Однако следует отметить, что показатель $Bias$ в использованных методах колеблется в пределах 14–19 % (при построении аддитивной модели), 10–12 % (при использовании ИНС). Данные показатели указывают на некоторое преимущество использования аппарата ИНС при прогнозировании температуры воздуха.

СПИСОК ЦИТИРОВАННЫХ ИСТОЧНИКОВ

1. Бодянский, Е. В. Искусственные нейронные сети: архитектуры, обучение, применения / Е. В. Бодянский, О. Г. Руденко. – Харьков: ТЕЛЕТЕХ, 2004. – 369 с.

2. Логинов, В. Ф. Сезонные особенности изменения климата Беларуси / В. Ф. Логинов, Ю. А. Бровка // Природопользование. – 2014. – Вып. 25. – С. 16–22.
3. Михалеп, С. Г. Использование анализа временных рядов в изучении многолетних температурных изменений / С. Г. Михалеп, Д. Э. Мингалев, С. И. Евдокимов // Вестник Псковского гос. ун-та. – Сер. Естественные и физико-математические науки. – 2014. – № 4. – С. 17–24.
4. Подгорная, Е. В. Особенности изменения климата на территории Республики Беларусь за последние десятилетия / Е. В. Подгорная, В. И. Мельник, Е. В. Комаровская // Труды Гидрометеорологического научно-исследовательского центра Российской Федерации. 2015. – Вып. 358. – С. 112–120.
5. Сирота, Е. А. Прогнозирование динамики временного ряда атмосферных температур на основе иерархических многослойных нейронных сетей / М. Г. Матвеев, В. В. Михайлов, М. Е. Семенов, Е. А. Сирота // Вестник Воронеж. гос. ун-та. – Сер. : Системный анализ и информационные технологии. – 2015. – № 4. – С. 144–150.
6. Хаупшева, М. Х. Анализ и прогноз значений среднегодовой температуры Крыма с использованием компьютерных технологий / М. Х. Хаупшева, Т. Л. Шугунов, Л. Ж. Шугунов // Успехи современного естествознания. – 2017. – № 1. – С. 100–104.

Материал поступил в редакцию 26.02.2019

VOLCHAK A. A., SIDAK S. V. On the issue of forecasting air temperature on the example of Belarus

The article explored the possibility of building a forecast of mean monthly air temperature values in two ways: using artificial neural networks (building networks, optimizing the structure and training networks were carried out using the StatSoft Statistica 13 software package); on the basis of the additive time series model built using Excel+Vba. Calculation performance indicators (EFF) and the systematic error module ($Bias$) were calculated for each method.

УДК 556.5.06 (476)

Волчек А. А., Зубрицкая Т. Е.

ДИНАМИКА РАСПРЕДЕЛЕНИЯ ВОДНЫХ РЕСУРСОВ БЕЛАРУСИ МЕЖДУ СЕКТОРАМИ ЭКОНОМИКИ

Введение. Значение воды в жизни общества трудно переоценить, поскольку количество и качество водных ресурсов определяет все виды хозяйственной, культурной, социальной и экологической деятельности человека. Именно поэтому различные аспекты водных проблем всегда будут своевременными. Необходимым и важным условием рационального использования водных ресурсов является наличие своевременной, достоверной и полной информационной базы о водных ресурсах, с помощью которой можно оценить фактическое водопотребление и водопользование, дать прогнозные оценки водных ресурсов в будущем. Кроме того, остро стоит проблема загрязнения природных вод вследствие сброса сточных вод и других видов антропогенного воздействия. Ухудшение и сокращение водных ресурсов может нанести огромный вред окружающей среде, снизить эффективность производства, сказаться на состоянии здоровья населения [1].

Целью настоящей работы является оценка динамики водопотребления по видам экономической деятельности в Беларуси, разработка мероприятий по повышению эффективности использования водных ресурсов.

Исходные данные и методика исследования. В работе использованы материалы Государственного водного кадастра Республики Беларусь за период 2010–2017 гг. [2].

Для выявления тенденций и изменений в использовании природных вод анализируются данные водопотребления по видам экономической деятельности, а также учетные данные по сбросу сточных вод.

Исследования водопользования осуществлялись с применением экономико-статистических, сравнительных и графических методик. Такое исследование позволило сделать выводы о реальных тенден-

циях изменения водопотребления в Республике Беларусь.

Результаты исследования и их обсуждение. Основными потребителями воды на территории Республики Беларусь с делением по видам экономической деятельности являются: сельское, лесное и рыбное хозяйство; обрабатывающая промышленность; производство и распределение электроэнергии, газа и воды. Это можно проследить в таблице 1, где приведены объемы использования воды по видам экономической деятельности в Беларуси за период с 2010 по 2017 год.

Ведущими отраслями обрабатывающей промышленности являются пищевая промышленность; текстильное производство, включая производство одежды; обработка древесины и производство изделий из дерева; химическое производство.

В промышленности вода используется для весьма разнообразных целей, как правило, в качестве теплоносителя или охлаждающего средства, для мойки гидротранспорта продукции и сырья, для паробразования и т. д.

Основными потребителями воды по предприятиям являются: производство нефтепродуктов, химическое производство и производство резиновых и пластмассовых изделий: ОАО «Нафтан» (г. Новополоцк), ОАО «Мозырский нефтеперерабатывающий завод», ОАО «Беларуськалий», ОАО «Гродно Азот».

Металлургический комплекс: ОАО «Белорусский металлургический завод», ОАО Завод «Легмаш».

Энергетика: ОАО «Газпромтрансгаз Беларусь».

Производство продуктов питания, напитков и табачных изделий: ОАО «Савушкин продукт», Белорусско-германское СП «Санта-Бремор».

Анализируя данные таблицы 1 за период наблюдений 2010–2017 гг., видим, что суммарное водопотребление по Беларуси