

КЛАССИФИКАЦИЯ МЕТЕОРОЛОГИЧЕСКИХ СЦЕНАРИЕВ ДЛЯ ИСПОЛЬЗОВАНИЯ В ПРЕДИКТОРАХ ЭНЕРГОПОТРЕБЛЕНИЯ ЖИЛЫХ МАССИВОВ ГОРОДА.

Вороненко Д. И.

Национальный технический университет «Харьковский политехнический институт»

Аннотация: Работа посвящена поиску и классификации метеорологических сценариев, для использования в качестве дополнительной входной информации в предикторах связанного потребления электрической и тепловой энергии в коммунально-бытовом секторе. В качестве математического аппарата для кластеризации погодных данных использованы самоорганизующиеся карты Кохонена. Результаты работы позволили улучшить качество прогнозов энергопотребления.

Ключевые слова: прогнозирование электропотребления, метеосценарий, карты Кохонена.

CLASIFICAREA SCENARIILOR METEOROLOGICE PENTRU UTILIZAREA LOR ÎN PREDICTOARELE CONSUMULUI DE ENERGIE ÎN CARTIERELE DE LOCUIT ORĂȘENEȘTI

Voronenko D. I.

Universitatea Tehnică Națională “Kharkiv Polytechnic Institute”

Rezumat: Lucrarea este consacrată cercetării și clasificării scenariilor meteorologice pentru utilizarea lor în calitate de informație suplimentară de ieșire în predictoarele consumului coerent al energiei electrice și termice în sectorul comunal. În calitate de aparat matematic pentru analiza de cluster a condițiilor meteo sunt utilizate hărțile autoorganizatoare ale lui Kohonen. Rezultatele lucrării au dat posibilitatea îmbunătățirii calității pronosticurilor consumului de energie.

Cuvinte-cheie: pronosticare a consumului de energie, scenariu meteo, hărți de Kohonen.

CLASSIFICATION OF METEOROLOGICAL SCENARIOS FOR USING IN PREDICTORS OF RESIDENTIAL AREA POWER CONSUMPTION

Voronenko D. I.

National Technical University “Kharkiv Polytechnic Institute”

Abstract: The work is dedicated to identification and classification of meteorological scenarios for using them as additional input information in predictors of coherent consumption of electrical and thermal energy in residential area. Kohonen self-organized maps were used as mathematical apparatus for clusterization of weather data. Research results led to quality improvement of energy consumption forecasts.

Key words: energy consumption forecasting, meteorological scenarios, Kohonen maps.

Введение

В последние десятилетие наиболее быстро развивающимся и сложным по количеству влияющих сил и доступным методам регулирования сектором энергосистем постсоветских стран является коммунально-бытовой сектор потребления. На фоне снижения потребления электроэнергии промышленными предприятиями, вызванного финансово-экономическим кризисом конца 90-х, коммунально-бытовой сектор, вооружаясь все новыми обогревателями, кондиционерами и другими бытовыми

приборами, постоянно повышает потребление. В этих условиях особую важность приобретает решение задачи точного оперативного прогнозирования бытового электропотребления.

Данная работа является частью комплексного исследования по построению предиктора связного потребления электрической и тепловой энергии на нужды отопления жилых массивов города, используемого при моделировании и управлении региональным энергопотреблением [5].

В качестве математического аппарата для моделирования энергопотребления используются искусственные нейронные сети, позволяющие воспроизводить чрезвычайно сложные зависимости и обладающие повышенной надежностью при работе с искаженными и неполными данными. Предиктор энергопотребления жилого массива города, разработанный для теплового района Харьковской ТЭЦ, описывается следующим выражением:

$$W'(t+1) = \text{NN}(\rho(t+1), \gamma(t+1), \underline{T}'(t+1), \overline{T}'(t+1), \underline{T}(t), \overline{T}(t), Q'(t+1), Q(t), W(t)),$$

где t – индекс текущего дня; ρ – показатель продолжительности светлого времени суток; γ – тип дня недели; \underline{T}' – прогноз минимальной ночной температуры; \overline{T}' – прогноз максимальной дневной температуры; \underline{T} – фактическая минимальная ночная температура; \overline{T} – фактическая максимальная дневная температура; Q' – планируемый отпуск тепла жилому массиву; Q – потребление тепловой энергии жилым массивом; W – потребление электрической энергии; W' – прогноз потребления электрической энергии; $\text{NN}(\cdot)$ – выполняемое нейронной сетью функциональное преобразование вход-выход.

В рамках данной структуры входных параметров модели нейронная сеть может быть обучена выдавать как одношаговые (на сутки), так и многошаговые (до одного месяца) прогнозы с уровнем абсолютной ошибки 3-5%. При этом исследования, выполненные с использованием алгоритмов пошагового включения и исключения переменных модели, а также алгоритма вычисления важности входных переменных модели, статистически показали, что определяющее влияние на точность и устойчивость прогнозов имеют погодные факторы. А значит, наиболее перспективным путем повышения качества прогноза является их более тщательный учет.

Для решения этой задачи необходимо детально оценить влияние фактических и, особенно, прогнозных метеорологических данных и выбрать наилучший формат их представления в предикторе энергопотребления.

1. Роль метеоданных при прогнозировании энергопотребления жилых массивов

В отечественных гидрометеоцентрах для прогнозирования погоды применяется синоптико-гидродинамико-статистический метод, основанный на формах атмосферных циркуляций [2]. Для составления прогнозов погоды используют подробно наполненные фактическими метеорологическими данными синоптические карты, прогностические карты барического поля и способы расчета тех или иных метеорологических элементов. Этот метод хорош для прогнозирования погоды для относительно больших территорий. При необходимости же точного прогноза на региональном уровне он не

всегда позволяет учесть микроизменения в атмосферных фронтах и влияния ландшафта.

Как известно, крупные города с большим количеством промышленных объектов создают специфический климат, являющийся результатом влияния хозяйственной деятельности человека. Поэтому изменения температуры в крупном городе, таком как Харьков, отличаются от изменений идущих вместе с фронтом. Например, в работе [4] показано, что из-за особенностей застройки и характера подстилающей поверхности во время отопительного сезона температура наружного воздуха существенно различается в разных районах города и его окрестностях.

Нами была проанализирована база погодных данных (замеры каждые три часа) для города Харькова за период от 1 июля 2001 по 1 августа 2005 года, собранная аппаратно-программным комплексом «Зевс» ООО «Харьковская ТЭЦ-5». Для анализа изменчивости температуры в разные сезоны года были построены графики (см. рис. 1) среднесуточных температур в летние и зимние месяцы.

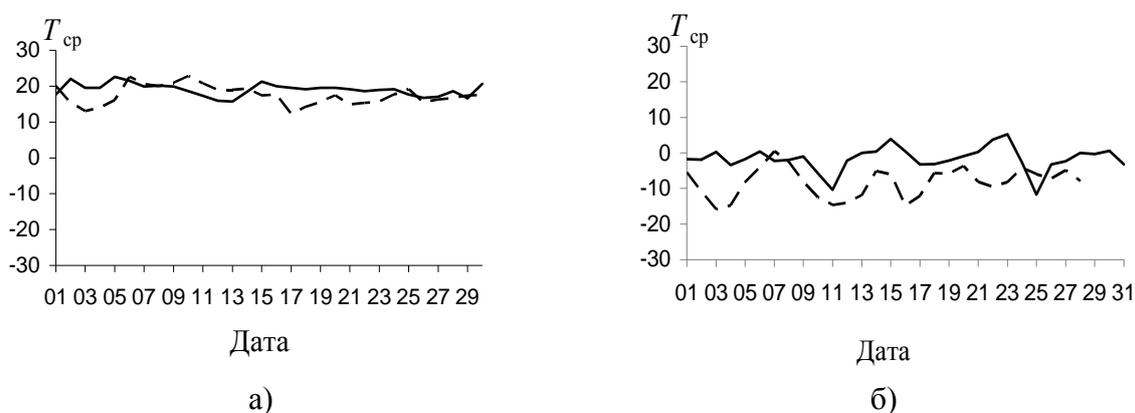


Рис. 1. Среднесуточная наружная температура в г. Харькове (2003 г.)
а) июнь (—) и август (---); б) декабрь (—) и февраль (---)

Подтверждая результаты исследований предыдущих лет [5], кривые на графиках демонстрируют, что в климатической зоне г. Харькова температура в зимние месяцы меняется намного резче, чем в летние. Это, в свою очередь, негативно сказывается на оправдываемости прогнозов температуры воздуха. Так согласно [2], прежде всего, велика абсолютная ошибка прогнозов – около 5°C . В весенние и осенние месяцы прогнозы значительно точнее – абсолютная ошибка составляет $3,5^{\circ}\text{C}$. В летние месяцы абсолютная ошибка прогнозов уменьшается до $2,4^{\circ}\text{C}$.

Все это говорит о том, что качество синоптических прогнозов особенно в отопительный сезон не является оптимальным. И это не может не сказываться на эффективности работы региональных систем энергоснабжения и, в частности на качестве теплоснабжения населения. Как указывается в [4], потенциальный экономический эффект от использования идеальных прогнозов температуры воздуха на предприятиях муниципального теплоснабжения вместо оперативных прогнозов текущего уровня оправдываемости может составлять до 25–30%.

В свете вышесказанного, наиболее рациональным путем учета сезонных особенностей изменения погоды в модели энергопотребления представляется выделение и использование в качестве входных переменных не отдельных значений наружной температуры, а сценариев ее развития. Разбиение динамики изменения температуры за несколько дней на отдельные метеосценарии позволит упростить

входную информацию предиктора энергопотребления и его внутренние связи на основе знаний, извлеченных из базы данных погоды, и полученных от экспертов.

Чтобы повысить уровень обобщения и уйти от абсолютных значений в метеосценарии, было предложено перейти к категориям, таким как изменение температуры вверх или вниз на определенное число градусов (или отсутствию значимого изменения за день).

Выбор количества дней, которые входят в метеосценарий, осуществлялся, руководствуясь следующими соображениями. Чтобы учесть естественный цикл смены тенденции погоды, установленный Мультиановским [3] и равный 12 дням, необходимо, чтобы продолжительность цикла Мультиановского была кратна количеству дней в метеосценарии. Таким образом, варианты следующие: 2, 3, 4, 6 дней. Два дня, очевидно, слишком малый промежуток для метеосценария, 3 дня дают $3^3=27$ вариантов изменения, если каждый день в ряду метеосценария кодировать одной из трех категорий (увеличение, уменьшение или неизменность температуры), 4 дня дают $3^4=81$ вариант, что представляется слишком сложным для экспертного и визуального анализа.

В поддержку выбора 3 дней для определения метеосценариев выступают также результаты работы проф. Вороновского [5], где показано, что наружная температура за 2 предыдущих дня еще влияет на энергопотребление, а большая история температуры не дает улучшения в качестве работы предиктора энергопотребления.

Таким образом, было решено при помощи статистических методов кластеризации выявить кластеры метеосценариев в базе архивных данных гидрометеоцентра г. Харькова за период с 1 октября 2001 года по 1 мая 2007 года и провести их анализ с экспертной точки зрения, чтобы использовать в дальнейшем данное разбиение на кластеры для прогнозирования температуры.

2. Выявление кластеров метеосценариев с помощью нейросетей Кохонена

Для статистического выявления кластеров метеосценариев было решено использовать нейросети Кохонена или самоорганизующиеся карты Кохонена, которые являются одним из наиболее передовых методов кластеризации. Нейросеть Кохонена учится понимать саму структуру данных, она может эффективно распознавать кластеры в данных, а также устанавливать близость классов [6], [7]. Эта ее особенность и явилась определяющей при выборе данного метода для решения задачи нахождения оптимального количества типов метеосценариев, исходя из структуры эмпирических данных, без вмешательства рассуждений экспертов и априорной информации, то есть исходя из данных нам Природой кластеров поведения погоды. Вместе с тем, к недостаткам карт Кохонена можно отнести наличие искажений, неизбежных при проецировании многомерного пространства на пространство меньшей размерности, а также зависимость результатов от параметров инициализации.

В связи с тем, что для практических задач оперативного управления энергоснабжением коммунально-бытовых потребителей, более важным является изменение температуры по сравнению с текущим значением, чем ее абсолютное значение, было решено использовать базу данных на основе изменений минимальной и максимальной температуры за последний и два предыдущих дня, а также средней текущей температуры. Данное разбиение является наиболее логичным, так как в данном случае мы ищем кластеры на основе изменений. Если искать кластеры на основе только абсолютных значений, то превалировать будут разбиения по принципу „тепло–холодно”, что не имеет практического значения для выявления метеосценариев.

На первом этапе исследований в базу данных для поиска кластеров метеосценариев были включены следующие переменные: сезон S , месяц M , атмосферное давление P ,

изменение минимальной температуры $\Delta T_{\min}(t)$, изменение максимальной температуры $\Delta T_{\max}(t)$, изменение минимальной температуры день назад $\Delta T_{\min}(t-1)$, изменение максимальной температуры день назад $\Delta T_{\max}(t-1)$, изменение минимальной температуры 2 дня назад $\Delta T_{\min}(t-2)$, изменение максимальной температуры 2 дня назад $\Delta T_{\max}(t-2)$.

По результатам первого эксперимента было решено исключить из набора входных данных параметры сезон S и месяц M . Так как если в набор данных входят сезон и месяц, то наибольший вес получают 4 и 11 кластеров, что рефлексировало 4 сезона года и 12 месяцев в году. Как показало визуальное исследование результатов, данные за июнь и июль были сведены к одному кластеру, поэтому во втором случае количество кластеров 11, а не 12. После исключения сезона и месяца кластеризация проводится только на основе цифровых данных, без экспертного деления на категории. Однако чтобы все же дать нейросети информацию о периоде года, было решено включить среднесуточную температуру как базис, от которого может отталкиваться нейросеть для разделения метеосценариев и их вероятностей.

Также на этом этапе исследования из набора входных данных было исключено атмосферное давление P , оказавшееся малозначимым метеорологическим фактором. Его различные значения распределены по различным кластерам хаотично, поэтому удаление давления не привело к изменению количества или расположения кластеров.

Таким образом, для дальнейших экспериментов набор входных переменных стал следующим: изменение минимальной температуры $\Delta T_{\min}(t)$, изменение максимальной температуры $\Delta T_{\max}(t)$, изменение минимальной температуры день назад $\Delta T_{\min}(t-1)$, изменение максимальной температуры день назад $\Delta T_{\max}(t-1)$, изменение минимальной температуры 2 дня назад $\Delta T_{\min}(t-2)$, изменение максимальной температуры 2 дня назад $\Delta T_{\max}(t-2)$, среднесуточная температура $T(t)$.

Карты Кохонена обучались со следующими настройками: количество итераций – 100; мера обучения – 0,1; размер сети – 40×40 ячеек; метрика для подсчета расстояния между точками – квадрат евклидова расстояния.

После обучения набор данных был разделен на 25 кластеров. Разбиение на кластеры и характеристические проекции каждой входной переменной представлены на рис. 2.

Для характеристических проекций карт Кохонена координаты по оси абсцисс и ординат не несут информационной нагрузки, так как проекция формируется в зависимости от близости многомерных точек, основная цель – группировка многомерного пространства в кластеры. Основную информационную нагрузку несет цвет или оттенок цвета. Шкала цвета показана на каждой диаграмме справа.

Согласно теории анализа карт Кохонена [6], [7] после обучения необходимо провести первичный визуальный анализ карт, т.е. в нашем случае, провести проверку как соотносятся найденные кластеры с изменениями температур и средней температурой, для подтверждения правильности статистической разбивки на кластеры.

При визуальном анализе не сложно заметить, что переменные $\Delta T_{\min}(t)$ и $\Delta T_{\max}(t)$, $\Delta T_{\min}(t-1)$ и $\Delta T_{\max}(t-1)$, $\Delta T_{\min}(t-2)$ и $\Delta T_{\max}(t-2)$, сильно коррелируют попарно. Возможно, стоит взять вместо пары экстремальных соответствующую среднесуточную температуру. Такое упрощение, с одной стороны, исключит некоторую информацию, с другой стороны, исключит избыточность. Так как в данном исследовании не стоит задача прогнозирования погоды, а только задача поиска кластеров, такое упрощение входной информации, с одновременным исключением сильно коррелирующих переменных, является вполне допустимым.

Таким образом, набор входных переменных для экспериментов с картами Кохонена, редуцируется до следующего: среднесуточная температура $T(t)$, изменение среднесуточной температуры между сегодняшним и вчерашним днем $\Delta T(t)$, изменение среднесуточной температуры между вчерашним и позавчерашним днем $\Delta T(t-1)$, изменение среднесуточной температуры между позавчерашним днем и 3 днями назад $\Delta T(t-2)$.

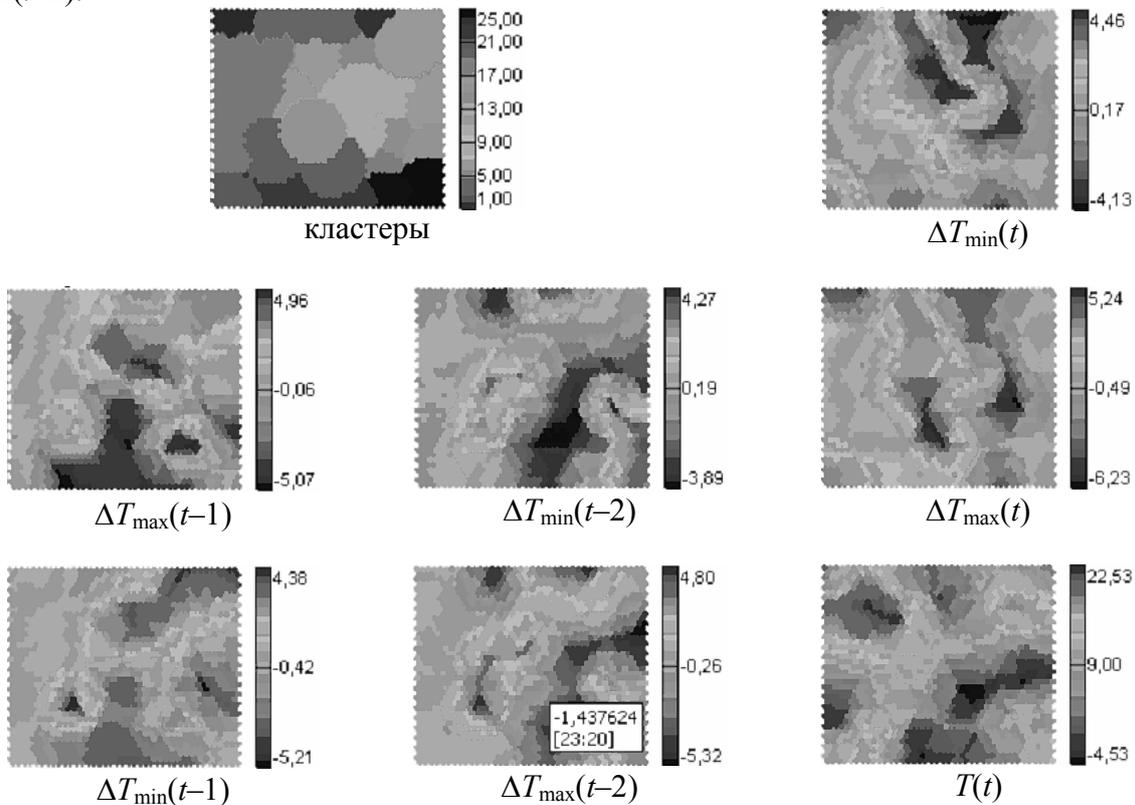


Рис. 2. Разбиение на кластеры и характеристические проекции входных переменных

При таком наборе, визуальный анализ (рис. 3) четко показывает, что все переменные описывают разные области пространства, т.е. эффективно разделяют пространство на кластеры.

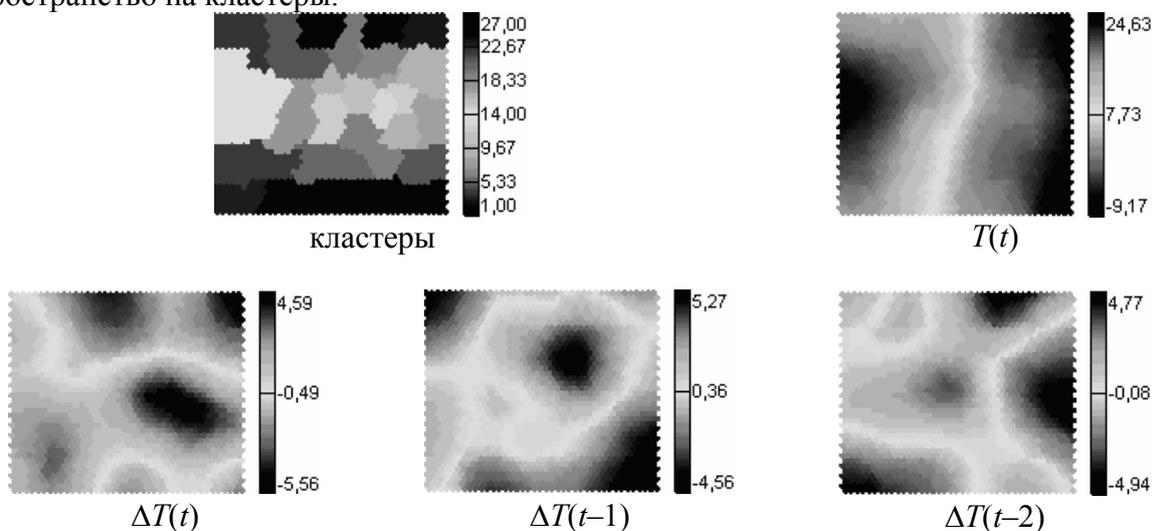


Рис. 3. Разбиение на 27 кластеров

Следующим вопросом является определение оптимального количества кластеров в наборе данных. Для его решения разработано несколько методов иерархической кластеризации. В данной работе был использован метод среднего объединения [7], который показал, что со статистической точки зрения оптимальными являются варианты: 2, 4, 7 и 27 кластеров. Поочередно тренируя и визуализируя нейросеть Кохонена при разбиении на указанное число кластеров, было выявлено, что наибольшим уровнем детальности и практической значимости обладает вариант 27 кластеров, который и принят для дальнейшего анализа.

3. Экспертное выделение базовых метеосценариев

Для выделения базовых метеосценариев был проведен следующий вид анализа – поиск практически значимых зависимостей внутри кластера. Он выполняется при помощи анализа визуального представления откликов нейросети Кохонена для записей, принадлежащих одному кластеру.

Основной задачей анализа откликов было извлечение знаний из кластерного разбиения, произведенного статистическим методом на основе исторических данных. Для каждой записи (т.е. для каждого дня и двух предыдущих дней) анализировалась ее одновременная принадлежность к тому или иному кластеру и паттерну (шаблону) изменения температуры. Чтобы соотнести непрерывные изменения дискретным паттернам, вычислялось изменение среднесуточной температуры для двух смежных дней. Если оно больше на 2°C , то следующий день считался днем повышения температуры; если меньше на 2°C - днем понижения температуры; если изменение не превышает 2°C в любую сторону, то погода считалась неизменной.

Уровень категоризации в метеосценариях, равный 2°C был выбран исходя из того, что обычно метеопрогноз считается оправдавшимся, если разница на текущий день составляет $1,5^{\circ}\text{C}$, на первые сутки – 2°C , на вторые – $2,5^{\circ}\text{C}$ и на третьи – 3°C [1].

Некоторые значимые паттерны, такие как неизменность температуры на протяжении 3-х дней или непрерывное повышение температуры на протяжении 3-х дней были видимы сразу, т.е. почти все записи, относящиеся к этим кластерам, соответствовали этому паттерну. Такие кластеры были названы гомогенными. В остальных кластерах записи, входящие в паттерн распределялись на несколько категорий. Методом проб и ошибок был выведен уровень гомогенности равный 84%, при котором кластеры оказалось возможным объединить в группы и получить экспертно значимое разбиение на 9 кластеров. Эти 9 кластеров названы базовыми метеосценариями поведения погоды за три последних дня.

Для удобства анализа базовых метеосценариев введено их графическое, мнемоническое и числовое кодирование, представленное в табл. 1.

В столбце «Графическое отображение метеосценария» прямая горизонтальная линия означает, что температура постоянна (т.е. изменилась не более чем на 2°C); наклонная линия вверх означает повышение температуры более чем на 2°C ; наклонная линия вниз означает понижение температуры более чем на 2°C ; горизонтальная линия из точек означает любой тип изменения температуры (понижение, повышение или неизменность температуры). Для удобства в столбце «Мнемоническое обозначение» каждому сценарию сопоставлена буква латинского алфавита или символ, напоминающий своей формой график движения температуры. В последнем столбце представлено числовое кодирование метеосценариев, используемое в разработанном программном обеспечении. Здесь «-1» обозначает понижение температуры в

соответствующий день из тройки анализируемых, «1» – повышение температуры, «0» – неизменность температуры и «*» означает любое поведение в соответствующий день.

Таблица 1 – Базовые метеосценарии

№	Графическое отображение базового метеосценария	Мнемоническое обозначение	Числовое кодирование
1		«A»	*, 1, -1
2		«V»	*, -1, 1
3		«-»	0, 0, 0
4		«/»	1, 1, 1
5		«\»	-1, -1, -1
6		«F»	*, 1, 0
7		«L»	*, -1, 0
8		«T»	*, 0, -1
9		«J»	*, 0, 1

4. Статистический анализ предикативной способности метеосценариев

В рамках исследований также был выполнен статистический анализ предикативной способности метеосценариев. Ниже представлена часть его результатов.

В табл. 2 приведено распределение наступления последующего метеосценария в зависимости от начального. Другими словами – вероятность следования одного метеосценария за другим. Каждая строка указывает начальный метеосценарий, столбцы – следующий за ним. Суммирование процентов в таблицах осуществляется по строкам.

Таблица 2 – Распределение частот следования базовых метеосценариев, %

	«A»	«V»	«-»	«/»	«\»	«F»	«L»	«T»	«J»
«A»	26,80	15,46	0	18,56	0	0	0	0	39,18
«V»	17,98	28,09	0	0	19,10	0	0	34,83	0
«-»	0	0	63,06	0	0	18,79	18,15	0	0
«/»	0	9,68	0	19,35	0	0	0	0	70,97
«\»	11,86	0	0	0	18,64	0	0	69,49	0
«F»	0	15,87	0	11,81	0	36,53	0	0	35,79
«L»	18,68	0	0	0	12,06	0	34,63	34,63	0
«T»	0	0	40,74	0	0	40,74	18,52	0	0
«J»	0	0	28,49	0	0	26,26	45,25	0	0

В табл. 3 приведено относительное распределение поведения температуры на следующий день после каждого из базовых метеосценариев. Каждая строка указывает начальный метеосценарий, столбцы – поведение температуры на следующий день

Таблица 3 – Распределение поведения температуры после метеосценария

Базовый метеосценарий	Изменение наружной температуры после метеосценария, %		
	снижение	постоянность	повышение
«А»	34,02	49,48	16,49
«V»	16,85	48,31	34,83
«←»	20,95	62,86	16,19
«/»	29,03	51,61	19,35
«\»	18,64	52,54	28,81
«F»	24,35	58,30	17,34
«L»	11,67	56,81	31,52
«T»	25,47	55,28	19,25
«J»	21,23	54,19	24,58

Как видно, почти для всех метеосценариев неизменная температура на следующий день проявляется в среднем в 50% случаев, что в очередной раз подтверждает практичность инерционного прогноза в случае отсутствия хорошей статистической модели. Однако, наиболее важно то, что некоторые метеосценарии с большей вероятностью предвосхищают повышение температуры на следующий день, например, такие как «V», «\» и «L», а некоторые – снижение, например, такие как «А» и «/».

Заключение

В ходе анализа базы данных погодных условий для города Харькова за 2001-2007 гг. с помощью кластерного анализа были найдены 27 статистических кластеров, на базе которых с помощью самоорганизующихся карт Кохонена были выделены 9 базовых метеосценариев.

Следует отметить, что преобразование указанных 27 статистических кластеров в 9 практически значимых базовых классов произошло в основном за счет индифферентности к поведению температуры в наиболее удаленный день (как можно заметить, в табл. 1 обозначение «*» встречается только для кодирования изменения произошедшего два дня назад). Таким образом, автоматическая кластеризация подтвердила, что более дальнее по времени изменение погоды играет меньшую роль, причем с точки зрения не только числового, но и сценарного подхода.

В качестве полученных новых знаний можно также отметить некоторые «нелогичности» в распределении метеосценариев по группам, например, с точки зрения экспертов кажется более правильным объединить сценарии типа «-1, 0, 1» и «0, -1, 1», как отображающие точку перегиба или смены в тенденциях погоды. Однако, согласно статистическим данным сценарий «-1, 0, 1» объединен со сценариями «0, 0, 1» и «1, 0, 1», что доказывает большее влияние поведения температуры в предыдущий день на прогноз поведения погоды на завтра, чем влияние общей формы движения температуры.

Категоризация динамики изменения температуры на метеосценарии позволяет осуществить более полный учет метеоинформации во входной информации предиктора

энергопотребления без резкого увеличения вектора его входов и, соответственно сложности настройки. Выявленные в результате данной работы типы метеосценариев были использованы как дополнительные входные параметры для предиктора энергопотребления. Это, совместно с переходом от прямого прогнозирования энергопотребления к прогнозированию его категорий, позволило повысить качество прогнозов.

Так как часть работы по оценке динамики изменения погоды фактически уже была выполнена кластерным анализом до начала статистического прогноза энергопотребления, вновь синтезированный предиктор для Алексеевского жилого массива г. Харькова показал увеличение числа верно предсказанных значений. И хотя прирост составляет порядка 2,5% от всех тестовых данных, он соответствует тем критическим ситуациям, в которых предыдущие версии предикторов давали неустрашимый высокий уровень ошибки, затруднявший их практическое применение.

Литература

1. Сорочинский М.А Гидрометеорологическое обеспечение организаций топливно-энергетического комплекса и пути его совершенствования // Труды ГНЦ СССР. – 1989. – вып. 302, с. 3-13.
2. Бурлуцкая В.М., Князева В.И. Опыт применения синоптико-гидродинамикостатистического метода к прогнозу температуры на третьи и пятые сутки. // Труды ГНЦ СССР. – 1978. – вып. 205, с. 26-37.
3. Мультиановский Б.П. Основные положения синоптического метода долгосрочных прогнозов погоды. – М.: ЦУУГМС, 1933. – Ч.1.
4. Хандожко Л.А. Методика оценки экономического эффекта прогноза температуры воздуха для ТЭЦ // Труды Главной геофизической обсерватории. – 1989. – № 528. – С.58-74.
5. Вороновский Г. К. Усовершенствование практики оперативного управления крупными теплофикационными системами в новых экономических условиях – Х.: Изд-во «Харьков», 2002.— 240 с.
6. Kohonen T. Self organized formation of topologically correct feature maps. // Biological Cybernetics. – 1982. – N43.- N.59-69.
7. Christopher M. Bishop Neural Networks for Pattern Recognition – Oxford University Press, Oxford, 1995. – 482 p.

Сведения об авторах

Д. И. Вороненко – аспирант кафедры электрических станций Национального технического университета «Харьковский политехнический институт», Украина, область научных интересов: применение искусственных нейронных сетей для прогнозирования в энергетике, e-mail: dvonko@gmail.com

Получено редакцией 4 сентября 2008 г.