

基于模糊认知图的气象要素预测模型

白雪,朱红康,吴瑞

(山西师范大学 数学与计算机科学学院,山西 临汾 041099)

摘要:根据气象要素相关性,构建气象要素预测模型,依据模糊认知图的推理机制实现对气象要素的预测,将对人类的疾病预防、环境污染等方面产生重要影响。该文将模糊认知图运用于气象要素中,提出一种基于模糊认知图的气象要素相关性分析及要素预测的模型构建方法。此模型综合考虑气象要素之间相互影响相互制约的关系,将气压、露点温度、湿度等九种不同的气象要素作为模糊认知图的概念节点,通过相关分析法将节点之间的相关程度数值化为各概念节点间的权重,得到初始关系矩阵,利用遗传算法对初始关系矩阵进行优化,优化后的关系矩阵和模糊认知图相结合对未来的气象要素进行预测。实验证明,该模型对气象要素的预测精度较高,实现了对气象要素预测的要求。但是实验中使用的气象数据规模有限,对模型的泛化能力有一定影响。总体来说该研究对推动气象要素预测具有积极的意义。

关键词:气象要素;模糊认知图;相关分析;遗传算法;预测

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2022)03-0186-06

doi:10.3969/j.issn.1673-629X.2022.03.031

Prediction Model of Meteorological Elements Based on Fuzzy Cognitive Map

BAI Xue, ZHU Hong-kang, WU Rui

(School of Mathematics and Computer Science, Shanxi Normal University, Linfen 041099, China)

Abstract: According to the correlation of meteorological elements, the prediction model of meteorological elements is constructed. The prediction of meteorological elements is realized by the reasoning mechanism of fuzzy cognitive map, which will have an important impact on human disease prevention and environmental pollution. In this paper, fuzzy cognitive map is applied to meteorological elements, and a model construction method based on fuzzy cognitive map is proposed for correlation analysis and element prediction of meteorological elements. The model comprehensively takes into the mutual influence and mutual restriction between meteorological elements account. Nine different meteorological elements, such as air pressure, dew point temperature and humidity, are regarded as the concept nodes of fuzzy cognitive map. The correlation degree between nodes is numerical converted into the weight among the conceptual nodes by correlation analysis method, and the initial relation matrix is obtained. The initial relation matrix is optimized by genetic algorithm. The optimized relation matrix and fuzzy cognitive map are combined to predict the future meteorological elements. The experiment shows that the model has high precision and meets the requirement of meteorological element prediction. However, the scale of meteorological data used in the experiment is limited, which has a certain influence on the generalization ability of the model. Generally speaking, this study has positive significance to promote the forecast of meteorological elements.

Key words: meteorological elements; fuzzy cognitive map; correlation analysis; genetic algorithm; prediction

0 引言

大气环境受到多种气象要素(风速、相对湿度、气温、气压、云量、降水量等)的综合作用,随着季节、时段、地理位置的改变,一个气象要素的变化会直接或间接地影响着其他一个或多个气象要素的变化。近来,许多学者研究发现气象要素的变化与全球灾害如干

旱、山洪、人类疾病如哮喘^[1]、过敏^[2]、季节性流感^[3]和登革热^[4]等的发作和冬季供暖^[5]和PM2.5^[6]等造成的大气污染息息相关。因此研究气象要素间的相关性是一项重要的预防措施。目前气象要素相关性主要依靠站点检测和分析,为气象要素的预测提供数据支持。然而,气象要素之间的影响过程错综复杂,包含多

收稿日期:2021-04-05

修回日期:2021-08-10

基金项目:国家社会科学基金重大招标项目子项目(17ZDA244);山西省互联网+与旅游产业升级协同创新中心项目(HLWLY2017012)

作者简介:白雪(1996-),女,硕士研究生,研究方向为计算机应用;朱红康,博士,副教授,研究方向为面向服务计算;吴瑞,博士,副教授,研究方向为Web挖掘、不确定理论。

种物理或化学变化过程,目前的气象模式也难以准确地描述大气中各种气象要素的相互变化关系,因此难以对其定性和定量计算进行预测。目前,用于研究气象要素的方法分为以下几类:数学模型和机器学习方法。钱悦等人利用基于后向轨迹 HYSPLIT 模型和潜在源解析 PSCF 对江西省(赣州市)臭氧污染特征与气象因子的关系进行了分析^[7]。尹晓梅等人利用后向轨迹及 WRF-CAMx 模式针对气象要素及污染物浓度进行了特征分析,得到了供暖结束前后的污染物演变规律^[8]。上述是基于现有数学模型的研究方法,在气象要素的分析研究中,机器学习的算法应用得越来越广泛,在预测方面表现出巨大的潜力。随着科学技术的发展,机器学习算法之一的神经网络已成为许多领域进行预测的强大工具。黄建风等人利用小波-NAR 神经网络技术,提出气象要素的时间序列预测原理与方法^[9],刘洋等人研究了降雨及其多种相关参数(PWV, 温度,相对湿度,露点温度,年积日,日积时)间的时变特征,并构建了基于径向基(radial basis function, RBF)神经网络的短期降雨预测模型^[10]。Peng Zhen 等人提出一种 PS-FCM 模型并将其挖掘方法应用于雾霾污染因果挖掘和预测^[11]。

基于气象要素的监测数据,采用智能算法进行分析,建立预测模型,已成为新的研究方向之一。然而采用现有数学模型进行分析模拟需要考虑本地化,设置相应的参数化方案。而且 WRF 都是中尺度模式,对于小尺度的模拟不够精确,所以模拟出来的分辨率还比较粗^[12]。而神经网络独有的黑匣子特性,导致无法解释其预测机理,随着模型预测规模的增加,误差也随之增加。

由于气象要素之间彼此制约的特点符合模糊认知图的运行机制,故该文章将 FCM 应用于气象预测领域,提出一种基于 FCM 的气象要素相关性模型。首先以相邻气象监测点的以时间为序列的数据集作为研究对象,对历史数据通过相关分析法获得影响权重,构建关系矩阵,进而建立气象要素相关性模型进行研究,可对未来的气象要素进行较为准确地推算。

1 模糊认知图

模糊认知图(fuzzy cognitive map, FCM)由节点和加权弧(连接,边)组成,它们以图形形式显示为带可选反馈环的带符号加权图。图上的节点表示描述系统行为特征的概念。概念可以是系统的输入、输出、变量、状态、事件、动作、目标和趋势^[13]。带符号的加权弧表示概念之间存在的因果关系。模糊认知图的推理使用一种源于神经网络的方法,可以迭代计算因子对彼此的影响。网络稳定之后,结果显示系统内的趋势。

由于模糊认知图允许反馈循环,新激活的概念可能会影响以前已经激活的概念,最后,激活通过非线性方式通过模糊认知图传播,直到系统达到一个稳定的极限环或者不动点^[14]。

图1说明了一个简单的 FCM,由六个概念 $l = 1, 2, \dots, 6$ 组成。这六个要素作为概念节点集合 C , $C = \{C_1, C_2, C_3, C_4, C_5, C_6\}$,同时也定义了各要素之间的关系权值矩阵 W ,如公式(1)所示,权重表示概念之间的因果关系。




图1 简单模糊认知图

$$W = \begin{matrix} & \begin{matrix} C_1 & C_2 & C_3 & C_4 & C_5 & C_6 \end{matrix} \\ \begin{matrix} C_1 \\ C_2 \\ C_3 \\ C_4 \\ C_5 \\ C_6 \end{matrix} & \begin{bmatrix} 0 & \omega_{12} & 0 & \omega_{14} & 0 & \omega_{16} \\ 0 & 0 & \omega_{23} & \omega_{24} & 0 & 0 \\ 0 & \omega_{32} & 0 & 0 & \omega_{35} & \omega_{36} \\ 0 & \omega_{42} & \omega_{43} & 0 & 0 & \omega_{46} \\ 0 & \omega_{52} & 0 & \omega_{54} & 0 & \omega_{56} \\ \omega_{61} & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \end{matrix} \quad (1)$$

Kosko^[15]提出了一规则,根据相互关联的概念的影响来计算每个概念的值,其中下列函数被归一化到区间 $[-1, 1]$:

$$g_i^T = f\left(\sum_{j=1, j \neq i}^n g_j^{T-1} \omega_{ij} + g_i^{T-1}\right) \quad (2)$$

其中, g_i^T 是概念在时刻归一化后的值($g_i^T \in [0, 1]$),而 $f(x)$ 是一个阈值函数,通常 $f(x)$ 是 sigmoid 型函数,用于约束 $f(x)$ 的值处于区间 $[0, 1]$,其中 $\lambda > 0$,表示 $f(x)$ 的陡度。

2 基于模糊认知图的气象要素预测模型

由于气象模式的不确定性和气象要素之间相互影响的特点,将模糊认知图应用到气象背景中,研究气象要素间的关系。

2.1 基于模糊认知图的气象要素相关性模型

利用 FCM 可以动态地衡量时间序列中概念的前一时刻对后一时刻的影响程度的特性,本节将 FCM 引

入气象要素的相关性建模中,建立一个气象要素相关性模型,将气象要素作为概念,要素之间的相关系数作为加权弧,通过 FCM 体现要素和要素之间的相关性。

构建的模糊认知图如图 2 所示。以九个气象要素 $l = 1, 2, \dots, 9$ 作为概念节点集合 C , $C = \{C_1, C_2, \dots, C_9\}$ 。将节点之间的关系表示为矩阵 W_l , 如公式(3)所示,节点之间的关系作为有向连线, w_{ij} 表示要素和要素之间的相关性,其中 w_{ij} 为正表示节点之间是正相关,为负则表示节点之间是负相关。 w_{ij} 根据公式(3)其初始关系权值可以算出。




图 2 模糊认知图

$$W_l = \begin{bmatrix} w_{11} & \cdots & w_{19} \\ \vdots & \ddots & \vdots \\ w_{91} & \cdots & w_{99} \end{bmatrix} \quad (3)$$

2.2 基于相关分析法的关系矩阵初始化

模糊认知图弧线上的值代表了连接这条弧线的概念之间的相关关系。首先将气象要素作为模糊认知图的概念节点,气象要素之间相关关系密切程度的测定,这里通过对相关系数的计算与检验来完成。对于两个要素 i 和 j ,如果它们的样本值分别为时间序列构成的向量,它们的样本值可以表示为 g_t^i, g_t^j , i 和 j 分别表示第 i 个气象要素和第 j 个气象要素,总共有 l 个要素。 t 表示每个气象要素的样本数, $i, j = 1, 2, \dots, l, t = 1, 2, \dots, n$, 它们之间的相关系数 w_{ij} 被定义为:

$$w_{ij} = \frac{\sum_{t=1}^n (g_t^i - \bar{g}_t^i)(g_t^j - \bar{g}_t^j)}{\sqrt{\sum_{t=1}^n (g_t^i - \bar{g}_t^i)^2} \sqrt{\sum_{t=1}^n (g_t^j - \bar{g}_t^j)^2}} \quad (4)$$

其中, \bar{g}_t^i, \bar{g}_t^j 分别表示要素 i 和要素 j 样本值的平均值,其定义如下:

$$\bar{g}_t^i = \frac{1}{n} \sum_{t=1}^n g_t^i \quad (5)$$

$$\bar{g}_t^j = \frac{1}{n} \sum_{t=1}^n g_t^j \quad (6)$$

w_{ij} 是要素 i 和 j 之间的相关系数,表示气象要素之

间的相关程度,处于 $[-1, 1]$ 之间。 $w_{ij} > 0$, 表示要素对要素有促进作用; $w_{ij} < 0$, 表示要素对要素有减弱作用; w_{ij} 的绝对值越接近于 1, 表示要素 i 和要素 j 之间的关系越密切, w_{ij} 的绝对值越接近于 0, 表示两要素无关。在该模型中, $l = 9$, 即共有 9 个概念节点,对于气压(P)和露点温度(Td)这两个要素来说,它们之间的相关性可以表示为:

$$w_{3,7} = \frac{\sum_{t=1}^n (g_t^3 - \bar{g}_t^3)(g_t^7 - \bar{g}_t^7)}{\sqrt{\sum_{t=1}^n (g_t^3 - \bar{g}_t^3)^2} \sqrt{\sum_{t=1}^n (g_t^7 - \bar{g}_t^7)^2}} \quad (7)$$

其中, g_t^3 表示第 t 个样本的气压取值, g_t^7 表示第 t 个样本的露点温度取值, \bar{g}_t^3 和 \bar{g}_t^7 分别表示气压列和露点温度列数据的平均值。

2.3 基于遗传算法的关系权值的优化

由于模糊认知图属于神经网络的一种,且之前受到专家领域的知识、经验和个人主观性的干扰,使得得出的结果缺乏一定的客观性。鉴于这个缺点,该文采用基于数据驱动的实数编码的遗传算法通过时间序列历史数据构成模糊认知图。

遗传算法包括选择、交叉、变异三个步骤,适应度 fitness 低的个体会被逐步淘汰,而适应度高的个体会越来越多,经过多代的自然选择后,保存下来的个体都是适应度很高的^[13]。err 表示适应度函数中预测值和真实值的均方误差。

$$\text{fitness} = \frac{1}{\text{err} + 1} \quad (8)$$

$$\text{err} = \frac{1}{L \cdot N} \cdot \sum_{i=1}^L \sum_{t=1}^N (\hat{g}_t^i - g_t^i)^2 \quad (9)$$

式中, N 为模糊认知图中概念节点的个数,即衡量个体的指标数, L 为模糊认知图中每个概念节点的原始数据的个数,即个体的个数。

利用模糊认知图对时间序列数据进行预测,该文采用一步领先预测的方法,即根据上一时刻的数据对下一时刻的数据进行预测的方法。即根据 $T-1$ 时刻的数据预测 T 时刻的数据。

$$\hat{g}_t^i(T) = f\left(\sum_{i=1, i \neq j}^L w_{ij} \times \hat{g}_t^i(T-1) + g_t^i(T-1)\right) \quad (10)$$

$f(\cdot)$ 表示激活函数,数据进行完一次迭代以后通过激活函数,其输出值即为预测值。激活函数可以将非线性因素引入到模糊认知图的计算当中,使得模糊认知图可以逼近非线性函数,这样模糊认知图可以应用到众多的非线性模型中。模糊认知图的结构源于神经网络,因此激活函数也与神经网络的激活函数一脉同源,在此采用 Tanh 函数作为激活函数。

$$f(x) = \frac{e^{2\lambda x} - 1}{e^{2\lambda x} + 1} \quad (11)$$

构建模糊认知图之前,先将数据集分为两部分。将一年中每个季节的70%数据作为训练集,将剩下的每个季节的数据作为测试集。

关系权值的优化流程如下:

(1)编码:将九个要素对自身的关系权值设置为1,要素的关系矩阵对应81个权值。需要将位于1和-1之间的81个权值进行实数编码, W 在遗传算法中称作染色体, $W_j = \{w_{11}, w_{12}, \dots, w_{99}\}$ 。

(2)初始化种群:构建过程中已经通过历史数据使用相关分析法确定了 j 个适应值较大的染色体 $W_j(j=1,2,3,4)$ 作为初始种群。

(3)适应度计算:按照公式(8)计算种群中每条染色体的适应度。

(4)选择:通过处理历史数据得到了最优染色体,此步骤将精简得出的每条染色体保留并参与交叉和变异操作,直接插入到新种群 pop 中。

(5)交叉:实验中设置交叉率参数 P_c 。该步骤的操作对象是实数串 W_j ,任选数串中的一个数据位置作为交叉点。例如染色体 W_1 ,若选中染色体中第三个元素 w_{13} 作为交叉点,则这条染色体第三个元素与之后的第九个元素相互交换,构成新的一条染色体参与下一步的变异操作。每次交叉之前,生成一个0到1的随机数,若该随机数大于 P_c 则进行本步操作,否则不进行。

(6)变异:设置变异率参数 P_t ,在变异之前产生一个0到1的随机数,如果该随机数大于 P_t ,则进行变异,否则不变异,变异时随机产生染色体中的位置,其值按照公式(12)进行修改,其中 r 为0到1之间的任意浮点数, $MaxPerturbation$ 为最大变异步长^[14]。

(7)迭代:重复执行第3到第6步,将变异后的新染色体插入到种群 pop 中,直到达到种群上限或者适

应度基本不变为止。

$$w = w + (r - 1.0) \times MaxPerturbation \quad (12)$$

关系权值优化的伪代码如下:

算法1:用实数编码遗传算法构建模糊认知图。

输入:训练集,初始化的权值矩阵,交叉概率 P_c ,变异概率 P_t ,最大迭代代数 T ,最大变异步长 $MaxPerturbation$

输出:最佳权值矩阵。

```

1. while i<T,do
2. 保存该种群中染色体的适应度
3. 将此染色体插入下一代种群 popj
4.   while n<pop. size do
5. 对此个体按交叉概率 $P_c$ 执行交叉操作
6. 对此个体按变异概率 $P_t$ 执行变异操作
7. 这个新染色体插入下一代种群 popj
8.   end while
9.   i++
10. end while

```

通过上述步骤构建出了基于模糊认知图的气象要素相关性模型,首先应用相关分析法将关系矩阵初始化,然后对初始化后的权值矩阵通过遗传算法进行优化。

3 实例与实验分析

3.1 数据的收集与处理

实验选取的是某市2018年末和2019年两个气象监测站点共24个点位的监测数据,观测了逐日逐时的地表温度(Dmt)、能见度(N)、本站气压(P)、降水量(R)、相对湿度(RH)、温度(T)、露点温度(Td)、风速(V)和云量(Y)九个气象要素数据。根据气温的起伏变化将实验数据分为四季,2018年12月到次年2月为冬季,3月到5月为春季,6月到8月为夏季,9月到11月为秋季。通过相关性分析与合并处理,最终得到乐山市一年中四个季节不同气象要素的相关系数。表1为3月份的部分数据。

表1 春季的部分气象数据

日期	DmT/℃	N/KM	P/hPa	R/mm	RH/%	T/℃	Td/℃	V/(0.1m/s)	Y
3.1	10.06	2.73	964.88	0.04	87.92	9.2	7.28	16.04	2.08
3.2	15.03	12.04	965.67	0	65.54	12.5	5.59	18.21	1.25
3.3	14.78	8.35	964.16	0	66.54	12.76	6.03	19.13	1.08
3.4	12.82	4.23	961.25	0	77.38	12.44	8.59	17.17	1.71
3.5	13.45	6.6	965.75	0	70.17	13.4	7.65	14.04	2.08
3.6	13.76	6.81	968.85	0.05	74.54	13.07	8.51	16.79	2.08
3.7	11.93	4.21	968.93	0.16	85.29	10.9	8.52	16.21	2.08
3.8	11.6	3.98	967.16	0.02	86.88	10.33	8.24	13.83	2.08
3.9	15.67	6.01	968.25	0	71.88	12.54	7	20.33	1.13

由上述表1和图3可知,各个要素的取值范围存在较大差距,因此在使用数据的时候需将数据进行预

处理。

数据预处理包括两个步骤:




图 3 春季气象要素的变化趋势

(1)除了降水量 R 这一指标外,对每个因素每天

表 2 春季数据的归一化值

日期	DmT/℃	N/KM	P/hPa	R/mm	RH/%	T/℃	Td/℃	V/(0.1m/s)	Y
3.1	0.010 4	0.002 8	0.993 9	0	0.090 8	0.009 5	0.007 5	0.016 5	0.002 1
3.2	0.012 4	0.995 8	0	0.067 7	0.012 9	0.005 8	0.018 8	0.001 3	0.015 1
3.3	0.995 5	0	0.068 5	0.013 2	0.006 2	0.019 8	0.001 1	0.013 2	0.004 3
3.4	0	0.079 8	0.012 8	0.008 9	0.017 7	0.001 8	0.013 9	0.006 8	0.989 8
3.5	0.072 5	0.013 8	0.007 9	0.014 5	0.002 1	0.014 2	0.007	0.996 3	0.000 1
3.6	0.013 5	0.008 8	0.017 3	0.002 1	0.012 3	0.004 4	0.997 8	0.000 2	0.087 4
3.7	0.008 8	0.016 7	0.002 1	0.012	0.004 1	0.999 3	0	0.089 3	0.010 6
3.8	0.014 3	0.002 1	0.016 1	0.006 2	1	0	0.074	0.012 9	0.007 2
3.9	0.001 2	0.017 3	0.007 6	1	0	0.065 5	0.014 9	0.007 1	0.017 6

3.2 关系矩阵的构建

FCM 中的权重矩阵可以用来分析因果关系和推断预测结果。首先运用气象学中常用的相关分析法初始化权重矩阵。图 4 为春季的初始化权重矩阵。

1	043509	01117	-00485	-06110	08834	03025	03848	-02741
01218	1	007528	01620	-067496	04751	-02147	02113	-02062
006268	004503	1	000914	02626	01576	01466	01018	00328
-00405	-01390	00156	1	01753	-00332	01328	012804	00495
-02760	-07352	02834	01237	1	-05460	03782	-02686	03302
07914	02778	005239	001292	-03904	1	05106	02885	-02190
05476	-03138	002815	01041	03817	06585	1	-001005	00755
-00557	02975	00919	002496	-03092	01017	-01828	1	-01797
-02745	-00732	00281	-00049	01361	-01457	-004595	00079	1

图 4 春季的初始权重矩阵




图 5 步长 r 的不同对应适应值的变化趋势

由于利用相关分析法得到的关系矩阵的适应度还存在改进的空间,利用公式(8)~公式(12)对矩阵不

的 24 个点的数据取平均值,对降水量 R 的 24 个数据求和,其结果作为当日的数据结果。

(2)由于站点数据的差异较大,因此对参与模型构建的数据进行标准化处理,将上一步处理好的数据压缩到 0 和 1 之间,这里采用公式(13)最大最小值法标准化数据结果。

$$g_i^i = \frac{G_i^i - \min(G_i^i)}{\max(G_i^i) - \min(G_i^i)} \quad (13)$$

其中, $\max(G_i^i)$ 和 $\min(G_i^i)$ 表示第 i ($i = 1, 2, \dots, 9$) 个节点代表数据的最大值和最小值。

以平均值为代表的春季的数据值归一化后的部分如表 2 所示。

断交叉变异,在迭代 10 000 次优化之后,将最大适应值的权重矩阵保存下来。经过实验发现不同的变异步长,得到的实验结果不尽相同,下面列举了五个不同的步长所产生的不同的适应值。图 5 为适应值随变异步长 r 的变化趋势。

表 3 不同步长对应春季关系矩阵的适应值

变异步长	适应值
0.002	0.936 2
0.003	0.936 1
0.004	0.936 2
0.01	0.937 4
0.02	0.936 3
0.03	0.936 1

观察图 5 和表 3 发现,当步长 r 取 0.01 时,适应值最高,则实验中的步长 r 即取 0.01。在迭代 10 000 次优化之后,得到的关系矩阵的适应值达到 0.937 4,较第一次的 0.9 的适应值有了较大改进,说明了遗传算法的合理性。

3.3 预测与误差

根据前文所述,将优化后的关系矩阵带入模型,对气象要素值进行预测,并计算其预测值与实际值之间的绝对误差和相对误差,最后根据相对误差来评价所

构建模型的预测精度。绝对误差 $e(t, i)$ 和平均相对误差 $Average(e(t, i))$ 的计算公式如下:

$$e(t, i) = |g_t^i - \hat{g}_t^i| \quad (14)$$

$$Average(e(t, i)) = \frac{1}{L} \sum_{i=1}^L e(t, i) \quad (15)$$

进行了如前文所述的实验,四个季节利用建好的模型得出的预测值与实际值之间的误差值如表4所示。

表4 实验得出的四个季节的适应值和误差

季度	平均误差
春季	0.049 758
夏季	0.061 149
秋季	0.084 940
冬季	0.063 652

3.4 实验结果对比

通过表5可以看出,该模型得到的预测值与实际值之间的误差均小于0.1,适应值均大于0.9,模型具有合理性。

表5 实验结果

	季节	相对误差	相对误差	相对误差
		最大值(max)	最小值(min)	平均值(avg)
Train	Spring	0.184 9	0.000 4	0.049 8
	Summer	0.259 6	0.004	0.061 1
	Autumn	0.265 4	0.002 4	0.084 9
	Winter	0.266 8	0.021 9	0.063 7
Test	Spring	0.204 1	0.017 2	0.119 5
	Summer	0.233 1	0.000 3	0.121 2
	Autumn	0.196 7	0.006 7	0.103 7
	Winter	0.229 1	0.024 3	0.138 6

4 结束语

通过利用模糊认知图对气象要素相关性进行分析建模,使得数据能进入模糊认知图中进行迭代,通过相关分析法对历史数据进行分析得到初始权重矩阵,通过遗传算法对初始权重矩阵数次优化,最后使模糊认知图迭代到一个稳定不动的平衡点后对气象要素进行预测。

实验表明,使用基于模糊认知图和遗传算法的优化模型进行气象要素相关性分析和要素预测具有可行性,将促进气象事业的进一步发展。但是该文只考虑了2019年的数据作为训练集和测试集,数据量不够大,同时对比方法不足。下一步考虑使用更多的历史数据,并使用其他方法以此构建精度更高,对比更明显

的预测模型。

参考文献:

- [1] RORIE A, POOLE J A. The role of extreme weather and climate-related events on asthma outcomes [J]. Immunology and Allergy Clinics of North America, 2021, 41(1): 73-84.
- [2] KATELARIS C H. Climate change and extreme weather events in Australia; impact on allergic diseases [J]. Immunology and Allergy Clinics of North America, 2021, 41(1): 53-62.
- [3] 郭倩, 陈涛, 周罗晶. 季节性流感与气象因素相关性的系统评价 [J]. 疾病监测, 2020, 35(12): 1081-1087.
- [4] 赵建国, 贾巧娟, 王丽莹, 等. 气象因素对登革热传播影响的研究进展 [J]. 现代预防医学, 2020, 47(22): 4185-4189.
- [5] 刘倬诚, 牛月圆, 吴婧, 等. 山地型城市冬季大气重污染过程特征及成因分析 [J]. 环境科学, 2021, 42(3): 1306-1314.
- [6] 张琛, 倪志伟, 姜婷. 基于WPTMM的PM2.5与气象条件关系的联合多重分形分析 [J]. 系统工程理论与实践, 2015, 35(8): 2166-2176.
- [7] 钱悦, 许彬, 夏玲君, 等. 2016~2019年江西省臭氧污染特征与气象因子影响分析 [J]. 环境科学, 2021, 42(5): 2190-2201.
- [8] 尹晓梅, 蒲维维, 王继康, 等. 北京地区2019年2~3月供暖结束前后两次污染过程特征分析 [J]. 环境科学, 2021, 42(5): 2110-2120.
- [9] 黄建风, 陆文聪. 基于小波-NAR神经网络的气象要素时间序列预测与天气指数彩虹期权估值 [J]. 系统工程理论与实践, 2016, 36(5): 1146-1155.
- [10] 刘洋, 赵庆志, 姚硕强. 联合GNSS PWV与气象参数的短临降雨预测 [C]//中国卫星导航系统管理办公室学术交流中心. 第十一届中国卫星导航年会论文集——S01卫星导航行业应用. 成都: 中国卫星导航系统管理办公室学术交流中心; 中科北斗汇(北京)科技有限公司, 2020: 6.
- [11] PENG Zhen, LIU Wanquan, AN Senjian. Haze pollution causality mining and prediction based on multi-dimensional time series with PS-FCM [J]. Information Sciences, 2020, 523: 307-317.
- [12] 董俊玲, 韩志伟, 张仁健, 等. WRF模式对中国城市和干旱地区气象要素的模拟检验和对比分析 [J]. 气象科学, 2011, 31(4): 484-492.
- [13] KANG Bingyi, DENG Yong, SADIQ R, et al. Evidential cognitive maps [J]. Knowledge-Based Systems, 2012, 35: 77-6.
- [14] 韩慧健, 韩佳兵, 张锐. 基于模糊认知图的物流需求预测模型研究 [J]. 系统工程理论与实践, 2019, 39(6): 1487-1495.
- [15] KOSKO B. Fuzzy engineering [M]. USA: Prentice-Hall, Inc. 1996.