

中图法分类号: TP301.6 文献标志码: A 文章编号: 1006-8961(2011)06-1030-08

论文索引信息: 刘皓挺, 李凡, 徐凤刚, 卢汉清. 利用图像质量评估空气质量的新方法 [J]. 中国图象图形学报, 2011, 16(6): 1030-1037

利用图像质量评估空气质量的新方法

刘皓挺^{1,2)}, 李凡²⁾, 徐凤刚²⁾, 卢汉清¹⁾

¹⁾(中国科学院自动化研究所模式识别国家重点实验室, 北京 100190) ²⁾(中国航天员科研训练中心, 北京 100193)

摘要: 图像质量的差异能够反映拍摄环境成像条件的差异。提出一种利用视频监控图像序列评估空气质量的新方法: 首先定义 3 类图像质量评估参数, 即图像的噪声亮度比、对比度以及模糊度来度量当前图像的质量; 其次对监控图像序列连续帧数据计算上述质量参数, 并将计算结果在时间轴上顺次连接形成 3 类时间序列数据; 再次对上述时间序列数据中的噪声亮度比采用 Gompertz 增长类型扩散过程模型进行建模与分析, 同时对对比度、模糊度参数使用降趋势波动性分析(DFA)方法进行分析; 最终通过对 Gompertz 模型以及 DFA 模型的模型参数的分析, 可以评估与解释空气质量程度的好坏。比较了晴天与雾天条件下模型变化趋势的不同, 大量实验亦表明此方法的有效性。

关键词: 图像质量评估; DFA; 扩散过程; 空气质量评估

The evaluation of air quality using image quality

Liu Haoting^{1,2)}, Li Fan²⁾, Xu Fenggang²⁾, Lu Hanqing¹⁾

¹⁾(National Laboratory of Pattern Recognition, Institute of Automation Chinese Academy of Sciences, Beijing 100190 China)

²⁾(Astronaut Research & Training Center of China, Beijing 100193 China)

Abstract: The intensity change of the image quality (IQ) can reflect the photography condition change of a CCD camera. A novel air quality evaluation method, which only uses the surveillance image, is presented in this paper. First, different IQ metrics, i. e. the noise brightness ratio, the contrast level and the blur level, are employed to evaluate the IQ. Then we use them to build different time series data. After that we utilize a Gompertz type diffusion process (GTDP) of stochastic growth and the detrend fluctuation analysis (DFA) method to analyze and fit the trend of these series above. Finally, we can use the parameters of the GTDP model and the DFA model to evaluate and classify the IQ change level of different atmospheres. Some experiment data, which are captured in a solar day and a misty day, are utilized to verify the validity of our method.

Keywords: image quality evaluation; DFA; diffusion process; air quality evaluation

0 引言

随着工业技术的不断发展, 空气污染问题对人们日常生活的影响日益加剧。为了克服这一问题, 相关部门不得不对空气污染程度进行实时监控, 以便在必要时采取一定的处理措施。最为直接的空

气污染监测方法^[1]为对诸如温度、湿度, 以及空气成分等指标进行采集和分析。然而这种方法存在明显的不足: 分析成本非常昂贵以及分析手段很复杂。近年来, 部分学者提出采用视频监控图像数据进行空气质量的分析。成像质量能够反映拍摄场景的环境亮度及对比度等信息的好坏, 这些指标能够被用来评估空气的质量。文献[2]介绍一种如式(1)所

收稿日期: 2010-05-20; 修回日期: 2010-07-15

基金项目: 中国航天员科研训练中心所长基金项目(SJ200902)。

第一作者简介: 刘皓挺(1981—), 男, 中国科学院自动化研究所博士研究生, 主要研究方向为模式识别、机器视觉、图像处理、数据挖掘, 已在国内外期刊及会议发表论文 15 篇。E-mail: imkyran@hotmail.com。

述的相机亮度与拍摄场景物理环境特性的模型。在这个模型中,相机亮度由大气中光的散射情况所决定,而散射现象本身又与大气中介质(如漂浮粒子)的物理属性相关联,因此该模型能够解释雾天相机成像比晴天成像对比度低的原因。这也说明图像质量的好坏能够被用来评估空气质量的差异。文献[3]通过结合遥感图像数据与视频监控图像数据,对某一地区空气质量的好坏程度进行监控与分析,并给出相应的空气质量分类算法。采用监控图像数据评估空气质量最大的好处在于其低廉的成本。然而目前为止很少有真正意义上完全通过视频监控图像数据评估空气质量的计算方法,其主要原因在于图像在拍摄过程中本身就存在较为明显的失真,因此很难通过单幅图像或比对多幅图像来评估拍摄环境的好坏。

$$E = I_{\infty} \times \rho \times e^{-\beta(\lambda)d} + I_{\infty} \times (1 - e^{-\beta(\lambda)d}) \quad (1)$$

式中, E 为 CCD 相机成像亮度; I_{∞} 为天空亮度; ρ 为场景中某点标准化辐射率; d 为场景中某点的景深; $\beta(\lambda)$ 为大气的散射系数; λ 为光波波长。

针对时间序列基本的两类变化模式,即增长(或下降)模式和波动模式,提出分别将 Gompertz 增长型扩散过程模型^[4]及降趋势波动性分析(DFA)^[5]时间序列分析技术应用于对图像质量的变化情况的评估,进而达到对空气质量评估的目的。该方法并非仅采用单帧图像的分析或多帧图像的比对进行评估,而通过对图像序列进行长期的观察,并对观察结果建立时间序列模型进行分析的。由于采用更大的数据量,同时也利用了图像帧间的关联信息,使得所得到结果的可靠性比单帧分析结果的可靠性更强,也更易于发现成像环境的变化规律。

1 算法计算流程

提出的算法计算流程如图 1 所示。具体算法计算步骤如下:

1) 算法对每一帧图像计算图像的噪声亮度比(NBR)、对比度以及模糊度等,用以分别描述图像的区域污染程度、区域灰度差异程度以及边缘差异程度等信息。与图像的对比度、模糊度不同的是:使用 NBR 度量来估计图像中所包含的噪声,一方面该值能够反映 CCD 相机的制造工艺水平,其强度的变化范围相对稳定;另一方面,对于监控用相机,主要讨论随机类型的噪声问题,因此定义 NBR 度量为噪

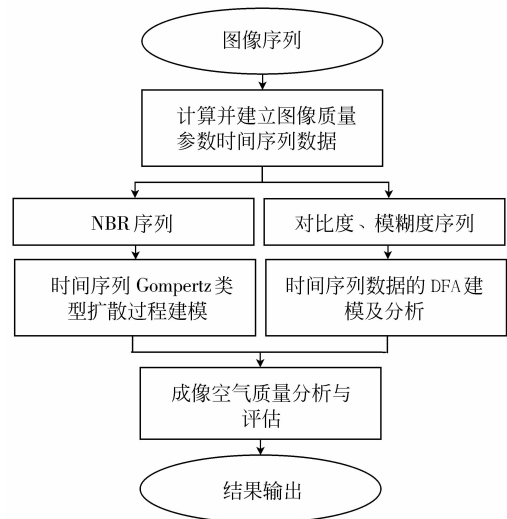


图 1 算法流程图

Fig. 1 The flow chart of proposed algorithm

声与亮度的比值,可有效提高算法的鲁棒性。

2) 算法将每一帧上所计算得到的 NBR 度量、对比度和模糊度等表示图像质量的数值在时间轴上顺次连接,形成时间序列数据,并采用 Gompertz 增长型扩散过程模型^[4]以及 DFA 技术对上述时间序列的变化情况进行拟合与分析。这里对 NBR 采用 Gompertz 模型进行建模分析,而对对比度与模糊度采用 DFA 模型进行分析,其原因在于对于特定天气下采集到的数据,NBR 表现出较为明显的增长变化趋势,而对比度与模糊度则表现出较为明显的波动性趋势。

3) 根据不同天气下 Gompertz 扩散过程建模以及 DFA 分析的结果,比较与分析诸如时间序列均值、极值、Gompertz 模型的参数以及 DFA 尺度指数等指标,完成对不同成像质量序列的评估与分类,最终达到评估与分类空气质量的目的。

2 图像质量参数

设计噪声亮度比代替噪声评估来判断图像质量。设计这个指标的原因在于:一方面,与其他评估度量参数相比,噪声的估计一般选取在图像灰度较为均匀的区域,因此其受图像内容的干扰较小;另一方面,随环境光线的变化,在一些特定的时间段内,CCD 相机的噪声强度一般会逐步增长或逐步降低,如黄昏时间段。这符合本文所采用的增长类型的扩散过程模型,因此满足本文评估的需要。然而,传统

的噪声估计方法主要是针对单帧图像进行噪声估计,对于监控图像数据而言,随时间的流逝噪声的变化受光线变化的影响较为显著,噪声的类型也随之发生变化,因此在噪声估计过程中需要考虑成像环境因素的变化。

文献[6]中介绍一种快速可靠的加性噪声估计方法,即计算图像局部区域的模值来估计噪声的强度,这里也采用该文献中介绍的噪声估计方法。通过比较研究,采用基于最小值的技术来近似模值估计的结果。仿真实验表明该种计算方法较为稳定,受光线变化干扰最小。为进一步增强噪声估计的鲁棒性,克服光线对噪声估计值的干扰,提出如式(5)(6)的计算方法,即将亮度因素作为噪声估计的参数(式(2))用来提高算法的鲁棒性。

$$\hat{\mu}_b = \left(\sum_{i=1}^N h_i \times (I_i)^p \right) / N \quad (2)$$

$$\hat{\mu}_k = \left(\sum_{i=1}^N I_{ik} \right) / N \quad (3)$$

$$\hat{\sigma}_k^2 = \sum_{i=1}^N (I_{ik} - \hat{\mu}_k)^2 \quad (4)$$

$$\hat{\sigma}_{\text{NBR}} = \hat{\sigma}_n = K_1 \times \ln(K_2 \times (255/\hat{\mu}_b)) \times \min_{k \in \Theta} (\hat{\sigma}_k) \quad (5)$$

$$M_{\text{NBR}} = \hat{\sigma}_n / \hat{\mu}_b \quad (6)$$

式中, I_i 为图像灰度值; I_{ik} 为第 k 块图像的图像灰度值; N 是采样块个数; Θ 为图像块集合; h_i 是直方图中灰度值为 I_i 的像素的个数; p 是图像亮度矩阶数, $p=3$; K_1, K_2 为控制参数。

所采用的对比度计算式如式(7)所示。如果定义图像边缘像素的宽度为边缘扩散距离^[7],那么模糊图像的边缘扩散距离应该比清晰图像的边缘扩散距离大,因此模糊度计算方法如式(8)所示。

$$M_c = \text{ave}_{i \in \Theta} \left(\sum_{k=1}^N (I_{ik}^{\max} - I_{ik}^{\min}) / (I_{ik}^{\max} + I_{ik}^{\min}) \right) / N \quad (7)$$

$$M_b = \max_{i \in \Theta} \{ \arctan \{ [I_{i1} - I_{i2}] / w_i \} \} \quad (8)$$

式中: I_k^{\max} 与 I_k^{\min} 为第 k 块图像子块灰度的最大值与最小值; N 为采样次数; I_{i1}, I_{i2} 为梯度方向的图像灰度值; w_i 为梯度扩散边缘的大小; $\text{ave}(\cdot)$ 表示计算括号内的均值。

3 扩散过程建模

3.1 建模方法简介

一般而言,形如式(9)的随机微分方程称为扩

散过程方程^[8]。与传统微分方程不同的是,扩散过程方程通过引入布朗运动项,使得其微分方程解的轨道在每一时刻迅速发生变化,进而模拟自然界真实的不确定性的物理现象。扩散过程建模的难点在于其模型参数的估计计算。常见的模型参数估计方法包括参数化估计方法与非参数化估计方法。参数化估计方法事先确定好扩散过程两类函数的基本形式,在此基础上采用统计推断的方法来确定函数中具体的未知参数。非参数估计方法则直接利用采样数据进行两类函数形式的估计。对于本文的问题,可以近似采用参数化的 Gompertz 增长类型的扩散过程对本文的实验数据进行建模。

$$dx_t = \mu(t; x_t) dt + \sigma(t; x_t) dB_t \quad (9)$$

式中: $\mu(t; x_t)$ 称为漂移系数; $\sigma(t; x_t)$ 称为扩散系数, B_t 服从标准布朗运动。

3.2 Gompertz 类型扩散过程

采用文献[4]中提出的一类新的 Gompertz 增长型扩散过程来描述监控 CCD 相机的 NBR 度量指标随时间变化的增长情况。式(10)(11)中分别给出了 Gompertz 扩散过程的漂移系数函数和扩散系数函数。一般而言,漂移系数函数控制扩散过程轨道的变化趋势;而扩散系数函数则控制随机波动程度的大小。根据 Kolmogorov 前向或后向方程^[8] 不难得到 Gompertz 过程所满足的转移密度函数的形式如式(12)所示。在初始分布一定的条件下,可以通过对其转移概率进行计算进而以获得不同时刻的状态分布。为了对该过程进行轨道的数值仿真,一般可采用如式(13)的随机泰勒展开式的形式进行轨道仿真。

$$\mu(t; x_t) = m e^{-\beta t} x_t \quad (10)$$

$$\sigma^2(t; x_t) = \sigma^2 x_t^2 \quad (11)$$

$$f(x, t | y, s) = \frac{1}{x \sqrt{2\pi\sigma^2(t-s)}} \times$$

$$\exp\left(-\frac{1}{2} \frac{[\ln x - \ln y + k_1(e^{-\beta t} - e^{-\beta s}) + k_2(t-s)]^2}{(t-s)\sigma^2} \right) \quad (12)$$

$$x_{t_{m+1}}^{(n)} = x_{t_m}^{(n)} + \mu(x_{t_m}^{(n)}) \Delta t_m + \sigma(x_{t_m}^{(n)}) \zeta_m + \frac{1}{2} \sigma(x_{t_m}^{(n)}) \sigma'(x_{t_m}^{(n)}) (\zeta_m^2 - \Delta t_m) \quad (13)$$

式中: $k_1 = m/\beta, k_2 = \sigma^2/2; \{\zeta_m\} \sim N(0, \delta)$ 独立同分布; m, β, σ 为 Gompertz 过程的控制参数; x_t 为 t 时刻的采样点大小。

3.3 Gompertz 扩散过程参数估计方法

根据上文得出的 Gompertz 过程转移概率函数可以采用最大似然估计方法计算其模型中的各个参数。首先对原始数据进行 d 次采样, 获得数据集 $\{x_{ij}\}_{i=1, \dots, d; j=1, \dots, n_i}$ 。设初始分布服从正态分布形式, 即形如式 $X(t_1) \sim \Lambda(\mu_1, \sigma_1^2)$ 。接下来根据转移概率函数可以得到分布函数, 采用最大似然估计的方法便可以推导出 Gompertz 过程各个参数的解析解。由于采用最大似然估计方法进行推导时, Gompertz 过程的参数并不能都得到显函数形式的解, 因此文献 [4] 中给出一种迭代的参数估计方法, 其计算速度较快, 因此本文也采用上述参数估计方法。

迭代的参数估计方法步骤如下: 1) 在时刻 $i=0$ 时, 生成 $(0, 1)$ 区间的随机数, 令其为 $b^{(0)}$ 值, 计算 $\beta^{(0)} = -\ln b^{(0)}$; 2) 根据式 (14) (15) 估计 $a_b^{(i)}$ 与 $m^{(i)}$ 的值; 3) 通过式 (16) 计算 $\beta^{(i+1)}$ 的值, 并估计 $b^{(i+1)}$; 4) 重复上述过程直至算法收敛终止; 5) 根据式 (17) 估计 σ^2 值。在上述迭代算法运算过程中, 对于较为复杂的方程, 可以采用蒙特卡罗马尔可夫链 (MCMC) [8] 算法进行近似求解与估计。

$$a_b^{(i)} = \frac{A_{1,b^{(i)}} A_{3,b^{(i)}}^* - A_{1,b^{(i)}}^* A_{3,b^{(i)}}}{((b^{(i)})^h - 1) [A_{1,b^{(i)}}^* A_{2,b^{(i)}} - A_{1,b^{(i)}} A_{2,b^{(i)}}^*]} \quad (14)$$

$$m^{(i)} = a_b^{(i)} \beta^{(i)} \quad (15)$$

$$\frac{k}{x_0} = \exp\left(\frac{m^{(i)}}{\beta^{(i+1)} e^{\beta^{(i+1)} t_0}}\right) \quad (16)$$

$$\hat{\sigma}^2 = \frac{2}{h} \frac{A_{2,b}^* A_{3,b} - A_{2,b} A_{3,b}^*}{A_{1,b}^* A_{2,b} - A_{1,b} A_{2,b}^*} \quad (17)$$

式中, $A_{1,b} = \sum_{i=1}^d \sum_{j=2}^{n_i} b^{t_{i,j-1}}$, $A_{3,b}^* = \sum_{i=1}^d \sum_{j=2}^{n_i} t_{i,j-1} b^{t_{i,j-1}} \ln \frac{x_{ij}}{x_{i,j-1}}$, $A_{1,b}^* = \sum_{i=1}^d \sum_{j=2}^{n_i} t_{i,j-1} b^{t_{i,j-1}}$, $A_{3,b} = \sum_{i=1}^d \sum_{j=2}^{n_i} b^{t_{i,j-1}} \ln \frac{x_{ij}}{x_{i,j-1}}$, $A_{2,b} = \sum_{i=1}^d \sum_{j=2}^{n_i} b^{2t_{i,j-1}}$, $A_{2,b}^* = \sum_{i=1}^d \sum_{j=2}^{n_i} t_{i,j-1} b^{2t_{i,j-1}}$, $k = \sum_{i=1}^d n_i$, $t_{ij} - t_{i,j-1} = h, i = 1, \dots, d, j = 1, \dots, n_i, a = m/\beta, b = e^{-\beta}$ 。

4 DFA 建模与分析技术

DFA 方法 [5] 自 1994 年被提出来, 已被广泛应用于许多领域, 如 DNA 序列分析、心电信号分析、经济学时间序列分析等。DFA 技术的优点在于其能够较为可靠的检测出非平稳时间序列的长程相关

性。因此本文采用 DFA 方法来分析图像的对比度与模糊度序列随时间波动的变化情况, 进而达到分析空气质量变化的目的。

一般而言, DFA 模型的计算步骤如下:

1) 对原序列做形如式 (19) 的变换:

$$\mu_y = \left(\sum_{i=1}^N y_i \right) / N \quad (18)$$

$$x(i) = \sum_{i=1}^N (y_i - \mu_y) \quad (19)$$

2) 把序列 $x(i)$ 分割成长度为 n 的 N_n 个不相交等长的子区间, 由于序列长度不一定是 n 的整数倍, 一般序列末尾会剩余一部分数据, 因此需要对原始序列从前至后, 以及从后至前执行上述步骤两遍, 即可得 $2N_n$ 个等长区间。

3) 采用最小二乘法拟合每一子区间 v ($v = 1, \dots, 2N_n$) 上的局部趋势 $p_v(i)$ 。其中 $p_v(i) = a_v + b_{v1}i + \dots + b_{v(k-1)}i^{k-1} + b_{vk}i^k$ 为 k 阶多项式。利用式 (20) 消除区间中的局部趋势项。

$$x_n(i) = x(i) - p_v(i) \quad (20)$$

4) 利用式 (21) 分别计算 $2N_n$ 个区间中的降趋势时间序列的平方均值, 最终用式 (22) 计算 DFA 分析的波动函数。

$$F_n^2(v) = \left\{ \sum_{i=1}^n x_n^2[(v-1) \times n + i] \right\} / n \quad (21)$$

$$F_q(n) = \left\{ \left[\sum_{v=1}^{2N_n} F_n^2(v) \right] / 2N_n \right\}^{1/q} \quad (22)$$

通常波动函数 $F_q(n)$ 是分割长度 n 的增函数; 给定 $\lg F_q(n)$ 与 $\lg n$ 函数关系图, 可定义其斜率为波动性尺度指标 α 。尺度指标 α 的取值反映了时间序列的相关性: 当 $\alpha = 0.5$ 时, 意味着序列是一个独立过程, 即序列不存在长期记忆性; 若时间序列仅短期相关, α 会十分接近 0.5; 当 $0.5 < \alpha < 1.0$ 时, 时间序列具有状态持续性; 当 $0 < \alpha < 0.5$ 时, 时间序列具有状态反持续性 (状态反持续性是指如果一个序列在前一个期间存在一个向上 (下) 的趋势, 则其在后一个期间则可能存在一个向下 (向上) 的趋势), 这种反持续性的强弱随 α 的减少而增强; 当 $\alpha = 1$ 时, 时间序列的相关性与 $1/f$ 噪声类似; 若 $\alpha > 1$, 序列的相关性不再是幂律的形式; 当 $\alpha = 1.5$ 时, 时间序列的相关性与布朗运动噪声相似。因此, 尺度指标 α 可作为描述原始时间序列“粗糙度”的指标, 尺度指标 α 越大, 时间序列越光滑。

5 实验验证与分析

本文算法的仿真采用 C++ 语言在主频为 2.66 GHz, 内存为 2 GB 的 PC 上实现。实验的硬件系统包括大容量硬盘 PC 一台, 全天候图像自动采集及存储软件一套, 以及两自由度监控用 CCD 相机一台。部分实验用测试数据样例如图 2 所示。由于采用可见光相机, 本文算法适合于解决晴天或雾天条件下空气质量的评估问题。为验证算法的正确性, 本文实验分别使用了北方冬季 11 月晴天与雾天的监控图像数据, 数据采集时间从 8:30—17:30; 相机系统实时采集图像数据, 处理软件每隔若干时间抽取一帧图像数据进行存储。由于本文所设计的 NBR 度量的计算不受图像采样的影响, 因此轻微的相机移动不会对算法估计的结果产生影响。在下文的算法验证中, 首先, 说明本文所设计的 NBR 度量对光线的鲁棒性较强; 其次, 通过数值仿真的方法说明本文所采用的 Gompertz 过程轨道特性及参数估计算法的正确性; 再次, 采用图 2 测试数据说明如何使用本文算法进行空气质量的评估与分类。




图 2 实验数据样例

Fig. 2 Samples of the experimental images

5.1 NBR 评估

从统计学的角度来看, 所提出的 NBR 度量实质就是统计学中的离散度。离散度用标准差除以均值, 这样计算可以剔除均值大小不等对评估结果的影响, 反映数据间差异的相对大小。表 1 中给出了部分实验数据及结果, 表中分别计算了常见的模估计方法^[6]: 均值算法 (average method), 最小值算法 (minimum method), 中值算法 (median method) 以及中值绝对偏差法 (median absolute

deviation method)^[9]。表中 σ'_{AVE} 为均值算法, σ'_{NBR} 为本文提出方法 (最小值方法), σ'_{MED} 为中值计算方法, σ'_{MAD} 为中值绝对偏差计算方法。光线的变化对噪声估计的结果有较大影响, 而本文提出的 NBR 度量则对光线变化有较强鲁棒性。图 3 给出了部分噪声评估图像样例。表 1 中“原图”代表没有进行暗化处理的图像, 而“暗图”则代表采用图像处理技术降低亮度的图像。从表 1 的结果可见本文所提出的噪声估计算法计算结果最为稳定。其中 σ_n 为人工加入的噪声方差, $K_1 = 1.8, K_2 = 1.1$ (参见式(5))。

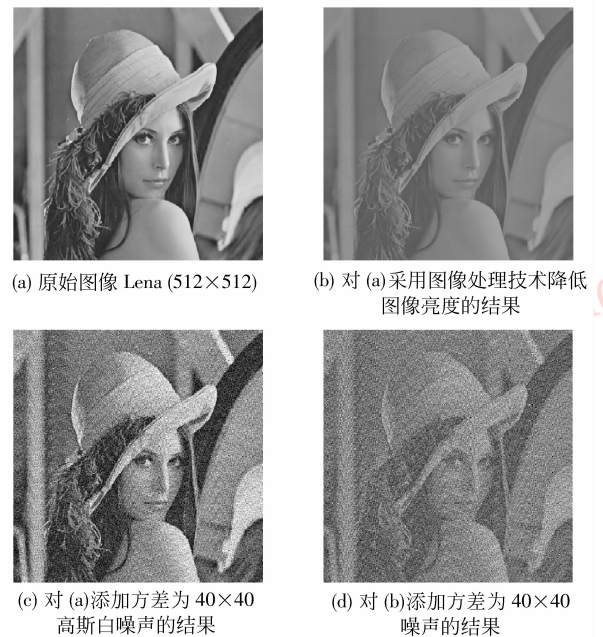


图 3 噪声评估实验图像样例

Fig. 3 Image samples of the noise evaluation experiment

表 1 NBR 参数评估结果

Tab. 1 Evaluation results of NBR metric

σ_n	σ'_{AVE}		σ'_{NBR}		σ'_{MED}		σ'_{MAD}	
	原图	暗图	原图	暗图	原图	暗图	原图	暗图
0	29.4	12.1	4.4	1.8	27.5	11.4	22.2	9.1
20	36.5	23.2	26.1	23.4	33.7	22.3	20.8	7.0
40	47.6	40.0	46.2	38.1	49.6	39.8	15.5	7.7
60	60.3	55.8	63.6	53.7	58.1	53.6	13.0	10.9

5.2 Gompertz 扩散过程建模评估

采用 Gompertz 增长类型的扩散过程来对 NBR 数据进行分析。图 4 中给出了 NBR 序列及 Gompertz 扩散过程轨道仿真结果。直观上看两类数据都有较强的随机波动趋势, 而黄昏采集的数据具有更强的增长趋势; 通过长期观察, 清晨采集的数据

虽然也有一定的增长趋势,但增长变化趋势较为缓慢。因此,比较而言这一时段采集到的数据一般不适合于用 Gompertz 增长型扩散过程建模。

图 4(c)中,扩散过程模型的参数分别为 $m = 1.20$, $\beta = 0.50$, $\sigma = 0.01$, 仿真的初始值 $x_0 = 1.50$, 步长 $h = 0.10$ 。




图 4 NBR 序列及 Gompertz 扩散过程轨迹模拟

Fig. 4 NBR series & the simulation path of the Gompertz diffusion process

表 2 中给出了 Gompertz 扩散过程参数估计计算方法的评估结果。如表 2 所示,首先本文按照数值仿真的方法(式(13))生成 Gompertz 扩散过程的轨道;在此基础上,利用上文中提到的参数估计算法迭代估计参数 m' 、 β' 和 σ' 。由表 2 中结果可见,文献[4]中算法对漂移系数的估计较为稳定和准确;而对扩散系数的估计则存在较大误差。同样的问题也经常出现在非参数的扩散过程参数估计方法中。出现这样的结果其原因除了算法设计本身的问题外,误差的传递也是造成漂移参数估计误差较大的主要原因。然而由于本文漂移系数主要控制扩散过程轨道局部的波动现象,因此在估计轨道与真实轨道误差允许的范围,也可以近似接受这样的结果。

不同,因此首先对原始数据进行诸如归一化预处理,使之与幅值较大的曲线处于同一数量级,在此基础上,使用 Gompertz 增长型扩散过程对其建模,以比较其参数的不同。如表 3 中所示,给出了简单的数据比较结果。从均值与极值的结果可见,雾天的数据普遍较晴天的数据小,这主要因为雾天光线较暗,因此 NBR 参数计算结果较小。

表 2 Gompertz 扩散过程参数估计方法评估

Tab.2 Evaluation of the parameters estimation method of the Gompertz diffusion process

初始点的个数 $N = 10$, 初始值 $x_0 = 1.5$, 步长 $h = 0.1$						
m	m'	β	β'	σ	σ'	
1.2	1.19	0.15	0.14	0.1	0.14	
1.0	0.97	0.15	0.12	0.1	0.32	
1.0	1.0	0.10	0.12	0.1	0.31	

表 3 不同天气下 NBR 数据的极值与均值比较

Tab.3 Comparison of the NBR mean and the NBR extremum of different atmosphere conditions

天气类型	均值	极大值	极小值
晴天	0.006 1	0.020 4	0.000 23
雾天	0.002 3	0.005 3	0.000 48

5.3 基于 Gompertz 建模的空气质量评估

图 5 中给出了不同天气下 Gompertz 扩散过程拟合的结果比较。图 5(a)给出了实验数据:蓝色曲线为晴天黄昏时分采集到的 NBR 数据,红色曲线为雾天黄昏时分采集到的 NBR 数据。为了比较计算结果,一方面,对序列曲线的幅度均值、极值进行比较;另一方面,我们同样需要比较两类曲线变化趋势的

从图 5(a)的结果中直观观察,晴天的数据比雾天的数据变化的程度明显。这个结果与肉眼观察的结果一致:因为晴天空气中诸如浮尘等的颗粒较小,随着时间的流逝,黄昏时分光线变暗的速度较快,因此根据式(1)可见成像质量变化也会较为明显;相反对于雾天由于空气中介质的影响,环境光强度则变化的较为缓慢,最终导致成像质量变化也较为缓慢。图 5(b)(c)给出了预处理后数据的 Gompertz 扩散过程拟合结果。图 5(b)(c)模型各自的参数分别为 $m'_1 = 1.18$, $\beta'_1 = 0.62$, $\sigma'_1 = 0.46$, $m'_2 = 1.19$, $\beta'_2 = 0.39$, $\sigma'_2 = 0.49$ 。从上述参数估计的结果来看, Gompertz 模型的参数 m 和 β 主要影响轨道增长趋势的强度,因此可以作为数据分类的主要参考指标;而参数 σ 影响轨道波动的强度,一般情况下在进行数据的分类时可以作为参考指标。




图 5 Gompertz 扩散过程拟合结果比较

Fig. 5 Fitting results comparison of the Gompertz process

5.4 基于 DFA 分析的空气品质评估

采用 DFA 模型的尺度指数参数 α 来分类、评估不同天气上午时分对比度(对应下标“c”)与模糊度(对应下标“b”)序列变化波动情况。图 6 中给出相关计算结果:晴天条件下波动函数 $F_{c1}(n)$ 与 $F_{b1}(n)$, 尺度指数参数 α_{c1} 与 α_{b1} (图 6(a)); 雾天条件下波动函数 $F_{c2}(n)$ 与 $F_{b2}(n)$, 尺度指数参数 α_{c2} 与 α_{b2} (图 6(b))。从图 6 中,如果取 DFA 模型的控制参数(见式(20)(22))为 $k_c = k_b = 4$ 及 $q_c = q_b = -10$ 时, $\alpha_{c1} = 0.999 > 0.5$ 、 $\alpha_{c2} = 0.834 > 0.5$ 、 $\alpha_{b1} = 0.620 > 0.5$ 、

$\alpha_{b2} = 0.613 > 0.5$,因此上述序列表现出持续的相关性。同时,通过上述结果还可得到如下关系式: $\alpha_{c1} > \alpha_{c2}$ 与 $\alpha_{b1} > \alpha_{b2}$ 。上述结果可以解释为:晴天空气中颗粒物的大小与密度比雾天空气中颗粒物的大小与密度低,晴天某时间段内相机亮度变化的强度比雾天相同时间段内相机亮度变化的强度要强,晴天相机成像质量参数估计值的变化趋势会比雾天相机成像质量参数估计值的变化趋势要强。通过上述的分析过程可见,可以利用 DFA 分析图像对比度与模糊度的方法进行成像空气质量的解释与评估。




图 6 图像质量参数 DFA 波动函数曲线计算结果

Fig. 6 Computation results of the DFA method

6 结论

介绍一种采用监控图像数据评估空气质量的新方法。通过综合采用 Gompertz 与 DFA 建模方法,分别对 NBR 度量、对比度、模糊度序列分析图像质量的变化趋势,进而达到评估空气质量变化的目的。

与同类技术相比,所采用方法的优点在于其实现成本低,计算速度快;不足在于算法主要针对特定类型的时间序列数据进行建模,因此数据的选择仍需人工干预。可以得出以下结论:1)采用监控图像数据评估和分类空气质量的技术途径是可行的;2)通过仿真实验可见本文所设计和使用的模型能够被用来完成空气质量的评估。在未来的工作中,一方面需

要进一步研究不同的图像质量评估参数和扩散过程模型,进而建立更为适合于描述空气质量变化的物理模型;另一方面相关的分类、聚类技术也将被研究,应用于对上述模型的自动分析与评估。

参考文献 (References)

- [1] Postolache O A, Dias Pereira J M, Silva Girao P M B. Smart sensors network for air quality monitoring applications [J]. IEEE Transactions on Instrumentation and Measurement, 2009, 58(9): 3253-3262.
- [2] Narasimhan S G, Nayar S K. Contrast restoration of weather degraded images [J]. IEEE Transactions on Pattern Analysis and Machine intelligence, 2003, 25(6): 713-724.
- [3] Wong C J, MatJafri M Z, Abdullah K, et al. Temporal and spatial air quality monitoring using Internet surveillance camera and ALOS satellite image [C] //Proceedings of IEEE Aerospace Conference. Montana, USA:IEEE, 2009: 1-7.
- [4] Gutiérrez-Jáimez R, Román P, Romero D, et al. A new Gompertz-type diffusion process with application to random growth [J]. Mathematical Biosciences, 2008, 208: 147-165.
- [5] Alvarez-Ramirez J, Rodriguez E, Echeverria J C. Detrending fluctuation analysis based on moving average filtering [J]. Physical A, 2005, 354: 199-219.
- [6] Aja-Fernández S, Vegas-Sánchez-Ferrero G, Martín-Fernández M. Automatic noise estimation in images using local statistics: additive and multiplicative cases [J]. Image and Vision Computing, 2009, 27: 756-770.
- [7] Wang Xin, Tian Baofeng, Liang Chao, et al. Blind image quality assessment for measuring image blur[C] //Proceedings of International Congress on Image and Signal Processing. Hainan: Hainan Normal University, 2008: 467-470.
- [8] Gong Guanglu. Introduction of the Stochastic Differential Function and Its Applications [M]. Beijing: Tsinghua University Press, 2008. [龚光鲁. 随机微分方程及其应用概要[M]. 北京: 清华大学出版社, 2008.]
- [9] Mazumder S, Serfling R. Bahadur representations for the median absolute deviation and its modifications [J]. Statistic and Probability Letters, 2009, 79(16): 1774-1783.