

DOI:10.13203/j.whugis.20180231



文章编号:1671-8860(2018)12-1811-08

使用量子优化算法进行高光谱遥感影像处理综述

张良培¹ 刘 蓉¹ 杜 博²

1 武汉大学测绘遥感信息工程国家重点实验室,湖北 武汉,430079

2 武汉大学计算机学院,湖北 武汉,430072

摘 要:高光谱遥感技术从 20 世纪 80 年代出现以来,已迅速成为对地观测的重要组成部分,其影像信息提取是地物信息提取的主要数据来源。高光谱遥感影像除提供地物的空间信息之外,其成百上千个波段携带的光谱信息所提供的诊断能力可以对地物目标进行精细化解译,大大增强了对地物信息的提取能力。充分利用高光谱遥感影像丰富的光谱信息对地物目标进行精细化解译成为近年来遥感领域的研究热点。对基于量子优化算法的高光谱遥感影像处理方法进行阐述,介绍了量子优化算法的发展与技术,并概括了其在高光谱遥感影像中的应用,并对量子优化算法在高光谱遥感影像处理中的应用发展提出建议和展望。

关键词:高光谱图像处理;量子优化算法;异常探测;端元提取;亚像元制图

中图分类号:TP75;P237

文献标志码:A

高光谱遥感能够获取地物目标在可见光、近红外、中红外和热红外波段范围的光谱信息,分辨率达纳米级^[1],可以提供诊断性光谱特征,在精细农业、环境监测、生物量估计等方面具有广泛的应用价值^[2-5]。

在高光谱遥感影像处理中,如分类、混合像元分解、亚像元定位等^[6-13],优化算法得到广泛应用,并取得了一定的成效。但是现有的优化算法存在不足之处,如全局优化能力不足,理论上并不能保证收敛到全局最优解,容易陷入局部极值;又如优化算法需要进行迭代处理,影像处理的效率低等。

被誉为 20 世纪伟大科学革命之一的量子力学尽管已有百年的历史,但其在信息科学中的应用仅仅始于 20 世纪 90 年代。用于因子分解的 Shor 量子算法^[14]和无序数据库搜索的 Grover 量子算法^[15]在 1994 年和 1996 年被相继提出,开创了量子计算的先河。量子智能优化算法则是将量子理论与智能计算相结合,利用量子并行计算的特性弥补了传统智能优化算法的不足,加快了算法的收敛速度,避免了早熟现象。与传统的优化算法相比,量子进化算法具有种群分散性好,全局搜索能力强,搜索速度快,易与其他算法相结合等

优点。根据解的编码及再生方式的不同,量子优化方法可以分为两种:一种是基于量子旋转门的量子优化算法,如量子蚁群算法(quantum ant colony algorithm, QACA)^[16]、量子遗传算法(quantum genetic algorithm, QGA)^[17]等;另一种是基于吸引子的量子进化算法,如量子粒子群算法(quantum-behaved particle swarm optimization, QPSO)^[18]。其中, QGA 和 QPSO 作为两类典型的量子优化算法,在量子优化领域占有重要的地位,已成为优化领域的研究热点。

1 量子优化算法的基本原理

1.1 量子遗传算法(QGA)

QGA 在遗传算法中引入量子计算的概念和原理,将量子比特概率幅的表示应用于染色体编码,量子旋转门等操作作用于染色体的更新,以此来寻找最优解。QGA 算法具有良好的全局搜索能力,能够在较小的种群规模下快速收敛到全局最优解。

在传统遗传算法中,染色体编码的经典方法大致分为二进制编码、数字编码和符号编码^[19]。QGA 采用基于量子位的编码方式。量子位是量

收稿日期:2018-08-14

项目资助:国家自然科学基金(41431175)。

第一作者:张良培,博士,教授,主要研究方向为高光谱遥感、高分辨率遥感及遥感应用。zlp62@whu.edu.cn

通讯作者:杜博,博士,教授。gunspace@163.com

子计算机中存储的最小信息单位^[20],一个量子位可能在“0”状态、“1”状态,或两者的任何叠加。一个量子位的状态可表示为:

$$|\varphi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (1)$$

式中, α 和 β 是量子位对应态的概率幅, $|\alpha|^2$ 和 $|\beta|^2$ 分别表示量子态被观测为“0”状态和“1”状态的概率;“1”里加数字表示量子位。状态的归一化需要满足:

$$|\alpha|^2 + |\beta|^2 = 1 \quad (2)$$

量子位是定义在一个二维复向量空间中的一个单位向量。采用量子位作为染色体的编码模式,一个量子位可由其概率幅定义为 $\begin{bmatrix} \alpha \\ \beta \end{bmatrix}$,一个 m -量子位可以表示为:

$$\begin{cases} \begin{bmatrix} \alpha_1 & \alpha_2 & \cdots & \alpha_m \\ \beta_1 & \beta_2 & \cdots & \beta_m \end{bmatrix} \\ |\alpha_i|^2 + |\beta_i|^2 = 1, i = 1, 2, \dots, m \end{cases} \quad (3)$$

基于量子位编码的量子种群可以定义为 $Q(t) = (q_1^t \ q_2^t \ \cdots \ q_n^t)$,其中 n 表示种群规模, t 表示遗传代数, q_j^t 表示一条量子染色体,其定义为:

$$q_j^t = \begin{bmatrix} \alpha_1^t & \alpha_2^t & \cdots & \alpha_m^t \\ \beta_1^t & \beta_2^t & \cdots & \beta_m^t \end{bmatrix} \quad (4)$$

式中, m 为量子位的数量,即量子染色体的长度。

一个 m -量子位的系统可以表示 2^m 个状态,由于量子系统能够描述叠加态,因此QGA具有比传统遗传算法更好的种群多样性特征,使算法能在较小的种群规模下求得最优解。用量子位来表示染色体也可以得到收敛,当 $|\alpha_i|^2$ 或 $|\beta_i|^2$ 接近0或1时,量子位染色体收敛到单一状态,多样性逐渐消失,所以用量子位对染色体进行编码同时具有勘探和开发两个特征。

量子门变换矩阵可以实现种群的更新,量子门变换矩阵 U 是一个可逆的归一化矩阵,即满足 $UU^* = U^*U = 1$ 。合适的量子门可以根据实际问题设计。常用的量子门有非门、控制非门、旋转门、异或门和Hadamard门等。Han等^[17]在解决组合优化问题时,采用了如下的量子旋转门来进行种群的更新:

$$U(\theta) = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix} \quad (5)$$

式中, θ 是旋转角度。

QGA算法流程如下。

1) $t=0$ 时,初始化群体 $Q(t)$;

2) 通过观察 $Q(t)$ 的状态得到二进制解集,利用适应度函数评价每个解的适应度,利用量子门 $U(t)$ 更新 $Q(t)$,保存当前最优解;

3) 算法终止条件:若满足终止条件,终止算法,执行步骤6),保存当前最优解,否则继续执行算法;

4) $t=t+1$;

5) 通过观察 $Q(t-1)$ 的状态得到二进制解集,利用适应度函数评价每个解的适应度,利用量子门 $U(t)$ 更新 $Q(t)$,保存当前最优解,执行步骤3);

6) 得到最优解,结束算法。

1.2 量子粒子群算法

在粒子群(particle swarm optimization, PSO)算法中,粒子的运动状态由位置和速度描述,随着时间的演化,粒子的运动轨迹是既定的;同时粒子的速度受到一定的限制,使得粒子的搜索空间是一个有限的逐渐减小的区域,不能覆盖整个可行解空间,故PSO算法不能保证全局收敛。针对PSO算法的这个缺点,根据粒子群基本收敛性质^[21],利用量子力学中相关理论作为背景知识,基于 δ 势阱模型的量子行为粒子群算法被提出^[18]。

在粒子群优化算法中,假设每个个体当前位置和速度分别为 $X_i(t) = (X_{i,1}(t) \ X_{i,2}(t) \ \cdots \ X_{i,p}(t))$ 和 $V_i(t) = (V_{i,1}(t) \ V_{i,2}(t) \ \cdots \ V_{i,p}(t))$,其中, $1 \leq i \leq M$, M 为粒子群中个体的数目; t 表示第 t 次迭代结果; p 为解空间的维度。那么,粒子群优化算法中速度更新公式为:

$$V_{i,j}(t+1) = V_{i,j}(t) + c_1 \cdot r_{1,i,j}(t) \cdot (P_{i,j}(t) - X_{i,j}(t)) + c_2 \cdot r_{2,i,j}(t) \cdot (G_j(t) - X_{i,j}(t)) \quad (6)$$

式中, $j=1, 2, \dots, p$; c_1 和 c_2 为权重系数; $r_{1,i,j}(t)$, $r_{2,i,j}(t) \sim U(0, 1)$; $P_i(t) = (P_{i,1}(t) \ P_{i,2}(t) \ \cdots \ P_{i,p}(t))$ 为每个粒子自身的最优位置; $G(t) = (G_1(t) \ \cdots \ G_j(t) \ \cdots \ G_p(t))$ 为所有粒子的全局最优位置。

由此得到经典PSO中粒子的位置更新公式:

$$X_{i,j}(t+1) = V_{i,j}(t+1) + X_{i,j}(t) \quad (7)$$

改变粒子在经典力学中的运动规律,在量子力学中,粒子的运动满足薛定谔方程:

$$i\hbar \frac{\partial}{\partial t} \Psi(X, t) = \left(-\frac{\hbar^2}{2m} \frac{\partial^2}{\partial X^2} + V(X) \right) \Psi(X, t) \quad (8)$$

式中, \hbar 表示普朗克常量; m 表示质量; $V(X)$ 表示能量分布函数; i 表示虚数。

假定粒子处于定态,即具有一定的能量状态,波函数的形式为:

$$\Psi(X, t) = \psi(X) e^{-iEt/\hbar} \quad (9)$$

式中, E 为相应的能量; $\psi(X)$ 为定态波函数。式

(9)代入式(8), $\psi(X)$ 满足定态薛定谔方程:

$$\frac{d^2\psi(X)}{dX^2} + \frac{2m}{\hbar^2}(E - V(X))\psi(X) = 0 \quad (10)$$

在对粒子运动有吸引力的 p 点建立一维 δ 势阱,粒子的位置为 X ,其势能函数表示为:

$$V(X) = -\gamma\delta(X - p) \quad (11)$$

令 $Y = X - p$,则粒子在 δ 势阱中的定态薛定谔方程为:

$$\frac{d^2\psi}{dY^2} + \frac{2m}{\hbar^2}(E + \gamma\delta(Y))\psi = 0 \quad (12)$$

其对应的定态薛定谔方程的解为:

$$\psi(Y) = \frac{1}{\sqrt{L}}e^{-|Y|/L} \quad (13)$$

式中, $L = 1/\beta = \hbar^2/(m\gamma)$ 。

在算法的实际设计中,为评价适应值(目标函数),需要了解粒子的精确位置,而量子状态函数 $\psi(Y)$ 仅仅给出粒子出现在相对于 p 点位置 Y 的概率密度函数 $Q(Y)$ 。为了给出粒子的精确位置,必须将量子状态塌缩到经典状态,这可以通过蒙特卡洛随机模拟方式来测量粒子的位置。由此,可以得到量子状态下的粒子群算法的基本进化方程:

$$X_{i,j}(t+1) = p_{i,j}(t) \pm \frac{L_{i,j}(t)}{2} \ln[1/u_{i,j}(t)],$$

$$u_{i,j}(t) \sim U(0,1) \quad (14)$$

令

$$p_{i,j}(t) = \varphi_j(t) \cdot P_{i,j}(t) + [1 - \varphi_j(t)]G_j(t),$$

$$\varphi_j(t) \sim U(0,1) \quad (15)$$

$$L_{i,j}(t) = 2\alpha \cdot \left| \frac{1}{M} \sum_{i=1}^M P_{i,j}(t) - X_{i,j}(t) \right| \quad (16)$$

式中, M 为粒子总数; α 为收缩-扩张系数(contraction-expansion coefficient),它是算法中除种群规模和迭代次数以外唯一的控制参数。对参数 α 的控制可以采用固定取值和线性减小的方式^[22]。则粒子的进化公式变为:

$$X_{i,j}(t+1) = p_{i,j}(t) \pm \alpha \cdot \left| \frac{1}{M} \sum_{i=1}^M P_{i,j}(t) - X_{i,j}(t) \right| \cdot \ln[1/u_{i,j}(t)],$$

$$u_{i,j}(t) \sim U(0,1) \quad (17)$$

2 基于量子优化算法的高光谱遥感影像处理

2.1 异常探测

高维光谱信息可以应用于不同的高光谱影像处理领域,高光谱目标探测是其中的主要任务之

一,目的是将目标像素或子像素与背景像素分离^[23]开来。

独立成分分析(independent component analysis, ICA)分解的目的是将观测所得数据线性分解为统计独立的分量,因此可以使用该特征来实现无背景模型的异常探测。为了降低 ICA 实现过程中陷入局部最优的几率,文献[24]提出了一种基于量子遗传算法(improved QGA, IQGA)的 ICA 算法,提高了检测精度与时间效率。主要改进如下。

1)通过替换两个个体的部分结构并重组进行交叉操作,产生新的下一代个体。通过交叉提高了搜索能力,从而能避免局部求解。该算法利用量子交叉的处理过程如下:①重新排列,这里采用随机排列;②得到第一个新个体,采用策略为将第一个个体的第一个基因作为新个体的第一个基因,第二个个体的第二个基因作为新个体的第二个基因,重复该过程,直到得到的新个体的基因数量和原来的一致;③重复上述策略,得到多个新个体,直到生成的新种群数量和原来的相同。

2)使用量子变异操作。突变主要是为了防止早熟收敛和保证局部搜索的能力。该算法中的量子突变是通过使用量子非门实现的。其实现策略为:首先根据突变概率 P_m 得到突变位置,然后对所选量子位的概率振幅进行量子非门操作。

假设观测到的信号矢量 $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_m]^T$ 是一个 m 维的随机向量,源信号向量 $\mathbf{S} = [s_1 \ s_2 \ \dots \ s_n]^T$ 是一个 n 维的独立随机向量,混合矩阵 \mathbf{A} 是一个 $m \times n$ 维的非奇异阵。其线性混合模型可表示为 $\mathbf{X} = \mathbf{AS}$,即为 ICA 模型。ICA 的原理是在 \mathbf{S} 和 \mathbf{A} 未知的情况下,根据所观察到的信号向量 \mathbf{X} 和源信号向量 \mathbf{S} 的统计信息来确定分离矩阵 \mathbf{W} ,得到结果 $\mathbf{Y} = \mathbf{WX}$,其中 $\mathbf{Y} = [y_1 \ y_2 \ \dots \ y_n]^T$,每个组分应该尽可能独立。

IQGA 采用非高斯最大化的方法来评估 ICA 模型,峭度或四阶累积量是经典的测量非高斯度的方法,其在理论和计算上都很简单。对 $\mathbf{Y} = \mathbf{WX} = [y_1 \ y_2 \ \dots \ y_n]^T$ 中的每一个变量的峭度的绝对值求和作为适应度函数,表示如下:

$$J(\mathbf{Y}) = \sum_{i=1}^n |\text{Kurt}(y_i)| = \sum_{i=1}^n |E\{y_i^4\} - 3(E\{y_i^2\})^2| \quad (18)$$

式中, $J(\mathbf{Y})$ 可以通过 \mathbf{X} 和 \mathbf{W} 最大化。在将峭度作为非高斯度量假设的情况下, $J(\mathbf{Y})$ 越大, \mathbf{Y} 中的变量独立性越强。为了保证零均值和 $E\{\mathbf{y}\mathbf{y}^T\} =$

I 的限制,在 IQGA 中对 X 和每一代信号变量应该采用中心化和白化处理,其中白化通过 ICA 实现。

2.2 端元提取

端元提取是高光谱图像处理中的热点和难点问题之一,其旨在解决广泛存在于高光谱图像中的混合像元问题。传统的端元提取方法基于线性混合模型和凸几何理论,通过寻找特征空间中由高光谱数据构成的凸几何的顶点来确定端元^[25-30]。

Liu 等^[31]及 Xu 等^[32]将基于量子行为的粒子群优化(quantum-behaved PSO, QPSO)算法用于端元提取,定义了编码方式,并改进了位置进化机制,改进如下。

1)使用像元在图像中所处的行列号对粒子进行编码。假设图像的空间大小为 $r \times c$,其中 r 是行数, c 是列数,图像中共有 p 个端元, M 个粒子,那么第 i 个粒子在第 t 次迭代时的位置可以表示为:

$$X_i^t = (X_{\text{row}_i}^{t,1} X_{\text{row}_i}^{t,2} \cdots X_{\text{row}_i}^{t,p} X_{\text{col}_i}^{t,1} X_{\text{col}_i}^{t,2} \cdots X_{\text{col}_i}^{t,p}),$$

$$i = 1 \cdots M \quad (19)$$

式中, $X_{\text{row}_i}^{t,k}$ ($k=1,2,\dots,r$)表示第 i 个端元在图像中的行号; $X_{\text{col}_i}^{t,k}$ ($k=1,2,\dots,c$)表示第 i 个端元在图像中的列号。根据 QPSO 方法中粒子位置的更新规则可以看出,粒子出现在离吸引子近的位置的概率高,出现在离吸引子远的位置的概率低。当采用此行列编码方式时,粒子将以更大的概率搜索距离当前时刻最优位置更近的点。而根据高光谱图像中自然地物的分布规律,地物一般呈同质性分布,即某一地物的纯净像元(最优解)一般就位于次优解附近。因此,粒子将以更大的概率搜索最优解,从而提高寻优效率。

2)采用合作机制对粒子的最优位置进行更新。原始的 QPSO 方法适用于解决低维优化问题,当优化目标的维度增加时,会造成维数灾难问题。端元提取也面临这一问题。这一问题的产生是由于在评价目标函数时,只对整个粒子对于目标函数的适应度进行了评价,而忽略了粒子中每个分量的影响。因此引入一个环境向量 b ,并将 b 用量子粒子群的最优位置(gbest)进行赋值。对每个粒子进行单个维度评价,最优位置的更新也是每个维度分别更新。例如当评价第 i 个粒子的第 j 维 X_{ij}^t 时,将环境向量 b 的第 j 维用 X_{ij}^t 进行替换,并利用替换后的 b 进行适应度的计算。通过这种方法,量子粒子群优化方法就不再受到维度的限制。

Xu 等^[32]将 QPSO 引入端元提取中时,主要改进如下。

1)采用高维的粒子群编码方式更符合端元的物理意义。将高光谱影像看作二维矩阵 $Y = [y_1 \cdots y_j \cdots y_N]$,矩阵中每列向量 $y_j = (y_{1j} \cdots y_{ij} \cdots y_{Lj})^T$ 为像素的光谱辐射值, L 为高光谱遥感影像的波段数, N 为遥感影像的像素数。图像中共有 p 个端元, M 个粒子,那么第 i 个粒子在第 t 次迭代时的位置可以表示为:

$$X_i(t) = (e_{i,1}(t) e_{i,2}(t) \cdots e_{i,p}(t)),$$

$$i = 1, 2 \cdots M \quad (20)$$

式中, $e_{i,j}(t) \in R$,表示第 i 个粒子中的第 j 个向量是一个光谱向量值。

2)利用变异操作保持种群的多样性,加快寻找的速度。将 QPSO 方法直接用于端元提取问题,虽然理论上能保证全局收敛,但在实际应用中也要考虑算法的效率。为加快算法的效率,引入变异操作。判断粒子 $X_i(t)$ 在下一时刻是否变异的原则是,首先确定一个变异概率 \bar{p} ,然后生成一个 $0 \sim 1$ 之间的随机数,如果随机数小于 \bar{p} ,那么意味着发生变异,否则不发生变异。

此外,文献[31]与文献[32]所用的端元提取的目标函数不同。在文献[31]中,目标函数被定义为最小化原始影像与重构影像之间的均方根误差(root mean square error, RMSE),而文献[32]中的目标函数为最大化以端元为顶点构成的单形体的体积。其目标函数可分别表示如下:

$$\min \text{RMSE}(\mathbf{Y}, \hat{\mathbf{Y}}) = \frac{1}{N} \sum_{i=1}^N \sqrt{\frac{1}{L} \|\mathbf{y}_i - \hat{\mathbf{y}}_i\|_2^2}$$

$$(21)$$

$$\min \text{Volume}(\mathbf{A}) = \frac{\left| \det \begin{bmatrix} 1 & 1 & \cdots & 1 \\ \mathbf{a}_1 & \mathbf{a}_2 & \cdots & \mathbf{a}_p \end{bmatrix} \right|}{(p-1)!}$$

$$(22)$$

上两式中, \mathbf{A} 是端元矩阵; \mathbf{Y} 和 $\hat{\mathbf{Y}}$ 分别是原始影像和重构影像。

将量子粒子群优化用于端元提取的实验表明,粒子群优化方法比传统的端元提取方法对噪声和异常更具鲁棒性,而 QPSO 方法比 PSO 方法的寻优能力更胜一筹。

2.3 亚像元制图

亚像元制图将混合像元内部端元所对应的丰度作为约束条件,按空间分辨率增强比将其分割成若干个亚像元,以此提高影像的空间分辨率,获得各类地物具体的空间分布情况^[33]。

文献[34-36]利用二进制量子行为粒子群算

法(binary QPSO, BQPSO)对以亚像元定位后连通区域周长最小为目标函数的算法进行迭代优化。基于改进的二进制量子行为粒子群算法的亚像元制图方法的目标函数由不同连通区域周长计算方法构成。目标函数如下:

$$\min C = \sum_{i=1}^{C_m} \sum_{j=1}^{C_n} p_{ij} \quad (23)$$

式中, C_m 表示类别数; C_n 表示第 i 类的连通区域个数; p_{ij} 为第 i 类第 j 个连通区域的周长。

在目标函数的优化中采用全局迭代与局部迭代相结合的优化策略,以减少时间复杂度。其中局部迭代是逐像元迭代,全局迭代是所有像元遍历一遍。BQPSO 对比 QPSO 来说,粒子的平均最好位置以及吸引子都是离散的,粒子位置的离散化更新引入了海明距离,粒子位置更新公式如下:

$$d_H(X_{ij}^{t+1}, p_{ij}^t) = [b] \quad (24)$$

$$b = \beta \cdot d_H(m_{\text{best}_j}^t, X_{ij}^t) \cdot \ln\left(\frac{1}{u_{ij}^t}\right) \quad (25)$$

上两式中, d_H 代表海明距离; u_{ij}^t 代表 0 到 1 之间的随机数; m_{best} 表示所有粒子的个体历史最优位置的平均值; β 为参数。已知 b 和 p_{ij}^t 就可以反推出粒子下一时刻的位置 X_{ij}^{t+1} 。但是式(24)并没有考虑到正负号的问题,容易导致算法早熟。MBQPSO(mutuation-based BQPSO)在此基础进行了改进,当随机数 $u_{ij}^t \geq 0.5$ 时,粒子下一时刻的位置就等于个体最优加上海明距离,当随机数 $u_{ij}^t < 0.5$ 时,粒子下一时刻的位置就等于个体最优减去海明距离。

在得到端元及其对应的丰度值后,设置一个丰度阈值判断像元是否为纯净像元。每个混合像元对应一个由 r^2 个亚像元组成的亚像元窗。设第 i 个像元包含 d 种地物,将丰度值按 $|s_{ik} \times r^2 - \text{round}(s_{ik} \times r^2)|$ 从小到大进行排序,则第 d 种地物在对应像元中亚像元的个数如下:

$$\begin{cases} n_{ik} = \text{round}(s_{ik} \times r^2), k = 1, 2, \dots, d-1 \\ n_{id} = r^2 - \sum_{k=1}^{d-1} n_{ik} \end{cases} \quad (26)$$

式中, d 表示地物的类别数; i 表示第 i 个像元; k 表示第 k 类地物; r 表示空间分辨率增强率; $\text{round}(\cdot)$ 表示四舍五入; s_{ik} 表示第 i 个像元中第 k 种地物对应的丰度。此时每个混合像元中每类地物所占亚像元的个数已知,但是不清楚具体位置。MBQPSO 通过最小化目标函数来得到地物正确的空间分布。为每个混合像元分配 m 个粒子,每个粒子为一个 $(d-1) \times r^2$ 的矩阵,每一行代表 $d-1$ 个端元,每一列代表相应端元在亚像元

窗口的位置。每一行该种地物对应的列赋值为 1,其余为 0。每个粒子每一行为 1 的个数必须为 n_k ,当个数不为 n_k 时,随机删除或增加 1 以确保总和为 n_k 。每个粒子的每一列只能有一个 1,其余都为 0,当某一列为 1 的个数超过 1 时,随机选择该行对应的一行赋值为 1,其余行的值为 0,并将赋值为 0 的行中所有行都为 0 的列赋值为 1。以上说明粒子的更新必须满足两个约束条件:①第 k 行只能有 n_k 个元素为 1;②每一列最多有一个元素为 1,也可都为 0。由此可以得到 $d-1$ 种地物的空间分布情况,也就知道了第 d 种地物的空间分布情况。

为了提高目标函数的适应性以及计算效率,MBQPSO 采用了 3 种连通区域周长计算方法来构成目标函数,修正了粒子位置更新的离散化过程,解决了 BQPSO 算法迭代过程中的过早收敛的问题。与原来的线性优化方法相比,很大程度上提高了分类精度。

2.4 端元提取实验结果展示

本节展示了传统粒子群算法和量子粒子群算法对真实高光谱图像的端元提取结果。使用的 3 种算法分别是文献[11]中的离散粒子群算法(discrete PSO, DPSO),文献[31]中的 QPSO 和文献[32]中的 MOAQPSO (mutation operator accelerated QPSO)。真实数据采用美国内华达州 Cuprite 地区的 AVIRIS 数据。Cuprite 地区从 20 世纪 70 年代起就成为了美国遥感地质研究的重要实验场地,美国地质调查局矿物谱库包含该地区主要矿区光谱,将该光谱库的矿物光谱作为参考端元。实验数据大小为 250×190 像素,除去噪声污染严重的波段以及水吸收波段,将剩下的 182 个波段作为输入数据,该数据覆盖了 $2.00 \sim 2.48 \mu\text{m}$ 的成像光谱范围。图 1 展示了该影像的假彩色图像。



图 1 Cuprite 数据集

Fig. 1 The Cuprite Image

各个方法提取出来的光谱角距离 (spectral angle distance, SAD) 值见表 1, 每个端元对应的最好提取结果用加粗字体表示。

表 1 不同算法的估计端元与真实端元的光谱角

Tab. 1 The Spectral Angle Distance Values Between Estimated Endmembers and Reference Endmembers for Different Algorithms

矿物名称	D-PSO	QPSO	MOAQPSO
镁铝榴石	0.050	0.061	0.055
蓝线石	0.095	—	0.076
蒙脱石#1	0.066	0.075	—
蒙脱石#2	0.046	0.052	0.044
钙铁榴石	0.060	0.059	0.054
绿脱石	0.084	0.071	0.066
玉髓	—	0.044	0.057
楣石	—	0.056	0.068
平均光谱角	0.050	0.052	0.053

从表 1 中可以看出, 不同的算法提取出来的矿物种类以及矿物数量是不相同的, D-PSO 只提取出了 6 种地物, 没有提取出玉髓和楣石, QPSO 和 MOAQPSO 都提取出了 7 种矿物, 但是 QPSO 没能提取出蓝线石, MOAQPSO 没能提取出蒙脱石#1。虽然 D-PSO 拥有最小的平均 SAD, 但是存在更多的类被重复提取或者漏提; QPSO 的 SAD 小于 MOAQPSO, 但是端元对应的最好提取结果较多, 所以单从表 1 只能判断两者都比 D-PSO 拥有更高的精度。

3 种算法原始影像和重构影像的 RMSE 分别为 D-PSO 算法 0.145 7, QPSO 算法 0.079 7, MOAQPSO 算法 0.092 6, QPSO 的 RMSE 最小, D-PSO 的最大。将 3 种算法提取出来的端元构成的单形体体积进行对比, QPSO 的体积最大, 为 2.48×10^{-42} , D-PSO 的体积最小, 为 3.44×10^{-46} , MOAQPSO 的体积为 2.13×10^{-42} 。由此可以得出量子行为粒子群算法比普通的粒子群算法提取端元的精度更高。

3 结语与展望

本文对量子遗传算法和量子粒子群算法进行了描述, 介绍了它们在高光谱遥感影像处理方法中的应用。到目前为止, 量子优化算法在高光谱影像处理中的研究不多, 但是已取得的研究结果令人很受鼓舞, 笔者认为在以下几个方面的工作值得进一步研究。

1) 在将优化算法用于高光谱遥感影像处理时, 对粒子的编码基本上都是沿用优化算法中原本的编码方法或者在别的应用领域使用过的编码

方法, 很少有方法结合高光谱数据本身的特性设计专门针对高光谱数据的编码方式。实际上, 不同的优化问题有其各具特色的搜索空间和解空间, 而粒子的编码方式直接影响了粒子在搜索空间中的运动方式。因此, 设计适用于高光谱影像处理的特定问题的粒子编码方式, 对粒子搜索最优结果的精度和效率有重要作用, 是值得考虑的研究角度。

2) 由于高光谱遥感影像的高维特性, 高光谱遥感影像处理的优化问题基本上都是多维或者高维优化问题。近年来有研究者对基本量子优化算法进行改进, 并有效地解决了高维的背包问题或者复杂的多峰值函数优化问题。但在应用于高光谱影像中时, 如果构建的目标函数计算复杂度较高, 会大大降低粒子的寻优效率。因此, 如何巧妙地将搜索空间低维化, 或者构建简单有效的目标函数, 也是一个重要的研究点。

3) 传统的遥感影像处理主要针对单源遥感影像, 近年来, 对地观测技术的发展为我们提供了具有不同成像特性的多源遥感影像; 此外, 自然地物或者人工地物的分布多种多样, 这些都决定了高光谱遥感影像的复杂性, 造成在对某一问题如影像分类或者目标提取进行建模时, 很难用单一目标函数进行有效的表达。因此, 在未来基于量子优化算法的高光谱遥感影像处理的研究上, 利用多目标优化理论解决多源遥感影像的分析与处理有望得到更好的结果。

参 考 文 献

- [1] Zhang Liangpei, Du Bo, Zhang Lefei. Hyperspectral Image Processing[M]. Beijing: Science Press, 2014(张良培, 杜博, 张乐飞. 高光谱遥感影像处理[M]. 北京: 科学出版社, 2014)
- [2] An Ru, Lu Caihong, Wang Huilin, et al. Remote Sensing Identification of Rangeland Degradation Using Hyperion Hyperspectral Image in a Typical Area for Three-River Headwater Region, Qinghai, China[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(3): 399-405(安如, 陆彩红, 王慧麟, 等. 三江源典型区草地退化 Hyperion 高光谱遥感识别研究[J]. 武汉大学学报·信息科学版, 2018, 43(3): 399-405)
- [3] Onojeghuo A O, Blackburn G A, Huang J, et al. Applications of Satellite 'Hyper-Sensing' in Chinese Agriculture: Challenges and Opportunities[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2018, 64: 62-86
- [4] Qin Zhanfei, Shen Jian, Xie Baoni, et al. Hyperspectral Estimation Model for Predicting LAI of

- Rice in Ningxia Irrigation Zone[J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(8):1 159-1 166 (秦占飞, 申健, 谢宝妮, 等. 引黄灌区水稻叶面积指数的高光谱估测模型[J]. 武汉大学学报·信息科学版, 2017, 42(8):1 159-1 166)
- [5] Yue J, Feng H, Yang G, et al. A Comparison of Regression Techniques for Estimation of Above-Ground Winter Wheat Biomass Using Near-Surface Spectroscopy[J]. *Remote Sensing*, 2018, 10(1):66
- [6] Zhong Y, Zhang L. An Adaptive Artificial Immune Network for Supervised Classification of Multi-/Hyperspectral Remote Sensing Imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(3):894-909
- [7] Zhong Y, Zhang S, Zhang L. Automatic Fuzzy Clustering Based on Adaptive Multi-Objective Differential Evolution for Remote Sensing Imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(5):2 290-2 301
- [8] Zhong Y, Zhao L, Zhang L. An Adaptive Differential Evolution Endmember Extraction Algorithm for Hyperspectral Remote Sensing Imagery[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(6):1 061-1 065
- [9] Zhong Y, Cao Q, Zhao J, et al. Optimal Decision Fusion for Urban Land-Use/Land-Cover Classification Based on Adaptive Differential Evolution Using Hyperspectral and LiDAR Data[J]. *Remote Sensing*, 2017, 9(8):868
- [10] Feng J, Jiao L C, Zhang X, et al. Hyperspectral Band Selection Based on Trivariate Mutual Information and Clonal Selection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(7):4 092-4 105
- [11] Zhang B, Sun X, Gao L, et al. Endmember Extraction of Hyperspectral Remote Sensing Images Based on the Discrete Particle Swarm Optimization Algorithm[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11):4 173-4 176
- [12] Zhang B, Sun X, Gao L, et al. Endmember Extraction of Hyperspectral Remote Sensing Images Based on the Ant Colony Optimization (ACO) Algorithm[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(7):2 635-2 646
- [13] Zhang B, Gao J, Gao L, et al. Improvements in the Ant Colony Optimization Algorithm for Endmember Extraction from Hyperspectral Images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2):522-530
- [14] Shor P W. Algorithms for Quantum Computation; [C]. IEEE Symposium on Foundations of Computer Science, Milwaukee, WI, USA, 1995
- [15] Grover L K. A Fast Quantum Mechanical Algorithm for Database Search[C]. 28th ACM Symposium on Theory of Computing, Philadelphia, USA, 1996
- [16] Li P, Li S. Quantum Ant Colony Algorithm for Continuous Space Optimization[J]. *Control Theory and Applications*, 2008, 25(2):237-241
- [17] Han K H, Kim J H. Genetic Quantum Algorithm and Its Application to Combinatorial Optimization Problem[C]. The IEEE 2000 Congress on Evolutionary Computation, La Jolla, USA, 2002
- [18] Sun J, Feng B, Xu W. Particle Swarm Optimization with Particles Having Quantum Behavior[C]. IEEE Congress on Evolutionary Computation, California, USA, 2004
- [19] Hinterding R. Representation, Constraint Satisfaction and the Knapsack Problem[C]. The IEEE Congress on Evolutionary Computation, Washington D C, USA, 1999
- [20] Hey T. Quantum Computing: An Introduction[J]. *Computing and Control Engineering Journal*, 1998, 10(3):105-112
- [21] Clerc M, Kennedy J. The Particle Swarm-Exploration, Stability, and Convergence in a Multidimensional Complex Space[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(1):58-73
- [22] Sun J, Fang W, Wu X, et al. Quantum-Behaved Particle Swarm Optimization: Analysis of Individual Particle Behavior and Parameter Selection[J]. *Evolutionary Computation*, 2012, 20(3):349-393
- [23] Du B, Zhang L. Target Detection Based on a Dynamic Subspace[J]. *Pattern Recognition*, 2014, 47(1):344-358
- [24] Li N, Du P, Zhao H. Independent Component Analysis Based on Improved Quantum Genetic Algorithm: Application in Hyperspectral Images[C]. IEEE International Geoscience and Remote Sensing Symposium, Seoul, Korea, 2005
- [25] Boardman J W. Automating Spectral Unmixing of AVIRIS Data Using Convex Geometry Concepts[C]. 4th Annu JPL Airborne Geoscience Workshop, Washington D C, USA, 1993
- [26] Winter M E. N-FINDR: An Algorithm for Fast Autonomous Spectral End-Member Determination in Hyperspectral Data[J]. *Proceedings of SPIE—The International Society for Optical Engineering*, 1999, 3 753:266-275
- [27] Chang C I, Wu C C, Liu W, et al. A New Growing Method for Simplex-Based Endmember Extraction Algorithm[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(10):2 804-2 819

- [28] Chan T H, Ma W K, Ambikapathi A M, et al. A Simplex Volume Maximization Framework for Hyperspectral Endmember Extraction [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(11):4 177-4 193
- [29] Du Q. A New Sequential Algorithm for Hyperspectral Endmember Extraction [J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(4):695-699
- [30] Luo W, Zhang B, Jia X. New Improvements in Parallel Implementation of N-FINDR Algorithm [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(10):3 648-3 659
- [31] Liu R, Zhang L, Du B. A Novel Endmember Extraction Method for Hyperspectral Imagery Based on Quantum-Behaved Particle Swarm Optimization [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(4):1 610-1 631
- [32] Xu M, Zhang L, Du B, et al. A Mutation Operator Accelerated Quantum-Behaved Particle Swarm Optimization Algorithm for Hyperspectral Endmember Extraction [J]. *Remote Sensing*, 2017, 9(3):197
- [33] Atkinson P M. Mapping Sub-pixel Boundaries from Remotely Sensed Images [J]. *Innovations in GIS*, 1997, 4:167-180
- [34] Villa A, Chanussot J, Benediktsson J A, et al. Unsupervised Methods for the Classification of Hyperspectral Images with Low Spatial Resolution [J]. *Pattern Recognition*, 2013, 46(6):1 556-1 568
- [35] Thornton M W, Atkinson P M, Holland D A. Sub-pixel Mapping of Rural Land Cover Objects from Fine Spatial Resolution Satellite Sensor Imagery Using Super-Resolution Pixel-Swapping [J]. *International Journal of Remote Sensing*, 2006, 27(3): 473-491
- [36] Ertürk A, Güllü M K, Çeşmeci D, et al. Spatial Resolution Enhancement of Hyperspectral Images Using Unmixing and Binary Particle Swarm Optimization [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(12):2 100-2 104

Hyperspectral Remote Sensing Image Processing by Using Quantum Optimization Algorithm

ZHANG Liangpei¹ LIU Rong¹ DU Bo²

1 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University,
Wuhan 430079, China

2 School of Computer Science, Wuhan University, Wuhan 430072, China

Abstract: Hyperspectral remote sensing technology has become an important part of ground observation since the 1980s, and it is the main data source of information acquisition for ground objects. Hyperspectral image (HSIs) not only contains spatial information, but also contains abundant spectral information with tens to hundreds of contiguous spectral bands. The abundant spectral information of HSIs can help us better identify ground objects, which has greatly improved our ability to qualitatively and quantitatively sense the earth's surface. It has been intensively researched to make full use of both spatial and spectral information of HSIs, so as to accurately obtain the information of ground objects. This paper reviews quantum optimization algorithm-based hyperspectral image processing methods. The development and methodology of quantum optimization algorithm as well as its application in hyperspectral image processing are introduced. And some suggestion and expectation for further study of the quantum optimization algorithm-based hyperspectral image processing are given.

Key words: hyperspectral image processing; quantum optimization algorithm; anomaly detection; end-member extraction; subpixel mapping

First author: ZHANG Liangpei, PhD, professor, specializes in hyperspectral remote sensing, high resolution remote sensing and remote sensing application. E-mail: zlp62@whu.edu.cn

Corresponding author: DU Bo, PhD, professor. E-mail: gunspace@163.com

Foundation support: The National Natural Science Foundation of China, No. 41431175.