

MATLAB
图像处理与识别

基于 MATLAB 和遗传算法的图像处理

鱼滨 张善文 郭竟 谢泽奇 编著 ■



西安电子科技大学出版社
<http://www.xduph.com>

MATLAB 图像处理与识别

基于 MATLAB 和遗传算法的图像处理

鱼 滨 张善文
郭 竞 谢泽奇 编著

西安电子科技大学出版社

内 容 简 介

本书系统介绍了 MATLAB 环境下遗传算法的功能特点及其在图像处理中的应用。全书共分为 7 章。第一章至第三章介绍遗传算法的基础知识,包括遗传算法的基本原理,编码、选择、交叉、变异,适应度函数,控制参数选择,约束条件处理,模式定理,改进的遗传算法,早熟收敛问题及其防止,小生境技术等。第四章介绍图像处理的基础知识,第五章介绍 MATLAB 遗传算法工具箱及其使用方法。第六章和第七章举例介绍多种基于遗传算法的图像分割、恢复、增强、拼接等方法,并给出了程序代码。

本书取材新颖,内容丰富,理例结合,图文并茂,注重应用。书中包含大量的实例和对应的程序代码,便于自学、应用和举一反三。

本书可作为高等院校计算机、自动化、信息、管理、控制与系统工程等专业本科生或研究生的教学参考书,也可供其他专业的师生以及科研和工程技术人员自学或参考。

图书在版编目(CIP)数据

基于 MATLAB 和遗传算法的图像处理/鱼滨等编著. —西安:西安电子科技大学出版社,2015.9

MATLAB 图像处理与识别

ISBN 978-7-5606-3635-1

I. ①基… II. ①鱼… III. ①Matlab 软件 IV. ①TP317

中国版本图书馆 CIP 数据核字(2015)第 210490 号

策划编辑 戚文艳

责任编辑 戚文艳 蓝 芳 武文娇

出版发行 西安电子科技大学出版社(西安市太白南路 2 号)

电 话 (029)88242885 88201467 邮 编 710071

网 址 www.xduph.com 电子邮箱 xdupfb001@163.com

经 销 新华书店

印刷单位 陕西华沐印刷科技有限责任公司

版 次 2015 年 9 月第 1 版 2015 年 9 月第 1 次印刷

开 本 787 毫米×1092 毫米 1/16 印张 18

字 数 426 千字

印 数 1~3000 册

定 价 33.00 元

ISBN 978-7-5606-3635-1/TP

XDUP 3927001-1

*** 如有印装问题可调换 ***

本社图书封面为激光防伪覆膜,谨防盗版。

前 言

人类传递信息的主要媒介是语言和图像。据统计,在人类接收的各种信息中视觉(即图像)信息占 80%,所以图像信息及其处理就显得十分重要。如今的信息化社会,图像是人类获取信息的最重要的来源之一。随着计算机技术的快速发展,图像处理技术与计算机技术不断融合,产生了一系列图像处理软件,这些软件的广泛应用为图像技术的发展提供了强大的支持。MATLAB 已成为国际公认的最优秀的科技应用软件之一,它具有编程简单、数据可视化功能强、可操作性强等特点,而且配有功能强大、专业函数丰富的图像处理工具箱,是进行图像处理方面工作必备的软件工具。图像处理是对图像进行分析、加工和处理,使其满足视觉、心理以及其他要求的实际应用技术,是计算机视觉领域内重要的研究内容。在对实际图像的获取、扫描、传输、特征提取、图像分割等过程中,可能造成计算机视觉实用化水平无法快速提高。要使误差达到最小,则需要对这些图像进行处理,其中涉及大量的优化计算。把 GA 应用到图像处理的最重要的一点是利用 GA 的全局搜索算法,快速取得函数最优解,从而得到较好的处理效果。本书将全面、系统地讲述应用在 MATLAB 环境下将 GA 应用于图像处理中,对图像进行压缩、增强、恢复,从图像中提取有效信息等。

本书内容围绕 GA 在图像处理中的应用,通过详实、丰富的实例讲解,引导读者逐步学会利用 GA 编写 MATLAB 程序解决图像处理中的实际问题。

本书的主要特点概括如下:

(1) 内容由浅入深。本书循序渐进地讲述 GA 的基础知识及其在图像处理中的应用,层次结构简洁明了,适合初学者学习 GA 和应用 GA 进行图像处理。

(2) 实例丰富,实用性强。本书打破了图像处理类图书理论多、算法多、实例少的惯例,重在 MATLAB 下的 GA 在图像处理中的实现及应用,重在实例。

(3) 语言简洁精练,可读性强。本书以简洁、通俗的语言来说明图像处理的基本理论,避免过于复杂的数学推导,提高了可读性和可用性。在实例的程序代码中,对关键的代码进行点睛式的注释,让读者在程序中快速有效地掌握 GA 的应用。

很多专家和学者为本书提供了基于 GA 的图像处理方面的资料和应用程序代码,西安电子科技大学出版社戚文艳编辑为本书的出版做了大量辛勤工作,在此一并表示感谢。正是多方面的支持才使本书得以呈献给读者。

需要特别指出,虽然作者竭尽所能,精心策划章节结构和内容编排,尽可能简明而准确地表述其意,但限于水平和资料,书中不足之处在所难免,恳请读者不吝指正。

作 者

2015 年 6 月

目 录

第一章 绪论	1
1.1 遗传算法基础	1
1.1.1 遗传算法的由来和发展	1
1.1.2 生物遗传与 GA 原理	3
1.1.3 GA 与传统方法比较	4
1.1.4 GA 的特点和优缺点	5
1.1.5 GA 中的一些术语	9
1.1.6 GA 的研究方向	10
1.1.7 MATLAB 与 GA 工具箱	11
1.1.8 基于 GA 的应用	11
1.2 图像处理基础	12
1.2.1 像素和分辨率	12
1.2.2 图像处理算法及其应用实例	15
1.2.3 GA 在图像处理中的应用	18
1.2.4 常见图像处理软件	19
第二章 遗传算法基础	22
2.1 遗传算法的理论基础	22
2.1.1 模式及模式定理	22
2.1.2 一个实例	27
2.1.3 有效模式数论	28
2.1.4 积木块假设	30
2.2 遗传算法的基本知识	32
2.2.1 编码	32
2.2.2 初始群体生成	36
2.2.3 遗传算子	36
2.2.4 适应度	46
2.2.5 约束条件	49
2.2.6 参数设置	50
2.3 简单 GA	51

2.4 GA 的实现过程	53
2.4.1 一般 GA 的流程	53
2.4.2 GA 的运行过程	55
2.4.3 利用 GA 求解一个简单问题	58
第三章 遗传算法中的主要问题及其改进	64
3.1 GA 的主要问题	64
3.1.1 欺骗和竞争问题	64
3.1.2 参数调节、终止条件判断、邻近交叉和收敛问题	67
3.1.3 GA-难问题	68
3.1.4 早熟收敛现象及其防止	69
3.1.5 种群的多样性	72
3.1.6 三个遗传算子对收敛性的影响	72
3.1.7 GA 性能评估	72
3.2 改进的 GA	74
3.2.1 改进 GA 的一般思路	74
3.2.2 改进 GA 之一	76
3.2.3 改进 GA 之二	77
3.2.4 改进 GA 之三	79
3.2.5 改进 GA 之四	80
3.2.6 改进 GA 之五	83
3.2.7 改进 GA 之六	84
3.2.8 改进 GA 之七	87
3.2.9 改进 GA 之八	89
3.2.10 微种群 GA	91
3.2.11 多种群 GA	92
3.2.12 遗传退火进化算法(GAEA)	95
3.3 并行 GA	96
3.4 多目标优化中的 GA	98
3.4.1 多目标优化的概念	98
3.4.2 多目标优化问题的 GA	99
3.5 基于小生境 GA 及其改进	103
3.5.1 小生境技术和共享函数	103
3.5.2 小生境 GA	104
3.5.3 改进的小生境 GA(NGA)	105

第四章 MATLAB 数字图像处理基础	107
4.1 基于 MATLAB 的绘图方法	107
4.2 MATLAB 的图像处理基础	111
4.3 基于 MATLAB 的图像处理方法	113
4.4 MATLAB 的图像恢复函数	126
4.5 图形的修饰与标注	130
4.6 MATLAB 环境下图像对象修改	131
第五章 基于 MATLAB 的遗传算法编程实现	133
5.1 安装 MATLAB 的 GA 工具箱	133
5.2 MATLAB 7.0 的 GADS 的主要函数及其参数	135
5.3 GADS 的主要函数详解	138
5.4 遗传工具箱 GADS 的 GUI 界面	146
5.5 基于 GATBX 工具箱的 GA 实例	150
5.6 GATBX 与 GADS 工具箱比较	154
5.7 GA 程序设计实例	156
第六章 基于遗传算法的图像分割方法	167
6.1 图像分割方法概述	167
6.1.1 图像分割基础	167
6.1.2 常用的图像分割方法	172
6.2 最大熵阈值图像分割	181
6.2.1 一维最大熵阈值分割	181
6.2.2 二维最大熵阈值分割	183
6.3 类间最大方差法(Otsu 法)	185
6.3.1 一维 Otsu 法	185
6.3.2 二维 Otsu 法	189
6.4 基于 Sheffield 的 GA 工具箱的图像分割	192
6.5 基于 GA 的全局阈值的图像分割	195
6.6 基于 GA 和分类类别函数的图像分割方法	196
6.7 基于 GA 的彩色图像分割方法	197
6.8 基于最大熵法和 GA 的图像分割算法	199
6.8.1 一维最大熵算法与 GA 相结合的图像分割	199
6.8.2 二维最大熵算法与 GA 相结合的图像分割	205
6.8.3 二维最大直方图熵法和改进 GA 的分割图像	210
6.9 基于 Otsu 与 GA 相结合的图像分割	214

6.10	基于 Otsu 和 GA 的多目标图像分割	220
6.11	基于二维 Otsu 和 GA 的图像分割	221
6.12	基于 Otsu 和改进 GA 的图像分割	222
6.13	基于遗传 K-均值聚类算法的图像分割	224
6.14	基于 GA 的指纹图像分割算法	226
6.15	基于遗传神经网络的图像分割	228
第七章	基于遗传算法的图像恢复、增强、拼接和匹配	234
7.1	基于 GA 的参数优化方法	234
7.2	基于 GA 的图像恢复	242
7.3	基于 GA 的图像倾斜检测与校正	246
7.4	基于 GA 的图像增强	249
7.5	基于 GA 的图像碎片拼接方法	256
7.5.1	基础知识	257
7.5.2	消除图像碎片拼接缝方法	257
7.5.3	基于 GA 的图像拼接	259
7.6	基于 GA 的图像匹配	261
7.6.1	图像匹配方法分类	261
7.6.2	基于 GA 的图像匹配方法	263
7.6.3	基于云 GA(CGA)的图像匹配	271
7.7	基于交互式 GA 的图像检索	272
7.8	基于 Otsu 和 GA 的图像边缘检测方法	276
参考文献		278

第一章 绪 论

遗传算法(Genetic Algorithm, GA)是一类借鉴生物界的进化规律(适者生存、优胜劣汰遗传机制)演化而来的随机化搜索方法,也是计算机科学、人工智能领域中用于解决最优化问题的一种搜索启发式算法。该方法能够生成有效的解决方案来优化搜索问题。目前,GA已经在图像校准、图像恢复、图像边缘特征提取、图像分割、图像压缩、三维重建优化以及图像检索等图像处理领域取得了成功应用,基于GA的图像处理新方法还在不断涌现。本章首先介绍GA的发展、基本原理和基本概念,描述GA的主要特点及其应用,最后介绍图像处理的基础知识。

1.1 遗传算法基础

GA是一种典型的启发式算法,是借鉴Darwin的自然选择学说和模拟自然界的生物进化过程的一种计算模型。下面介绍GA的基础知识。

1.1.1 遗传算法的由来和发展

随着人工智能应用领域的不断拓展,传统的基于符号处理机制的人工智能方法在知识表示、处理模式信息及解决参数组合爆炸等方面所碰到的问题已变得越来越突出,这些问题使一些学者对人工智能及其可能性提出了质疑和批判。众所周知,在人工智能领域中,有不少问题需要在复杂而庞大的搜索空间中寻找最优解或准优解,如货郎担问题和规划问题等组合优化问题。在求解此类问题时,若不能利用问题的固有知识来缩小搜索空间,则会产生搜索的组合爆炸。因此,研究能在搜索过程中自动获得和积累有关搜索空间的知识,并能自适应地控制搜索过程,从而得到最优解或准优解的通用搜索算法一直是令人瞩目的课题。GA就是在这种背景下产生并经实践证明特别有效的算法。

Darwin的进化学说指出,生命体在自然环境下,经过长期进化后,强壮个体能够适应环境、繁殖后代进而生存下来。在后代个体中,大部分与自己的上一代有着相似的性状,这种现象称为遗传;个别个体与自己的上一代有着迥异的差距,这种现象称为变异。个体遗传和变异的产生都是为了更好地适应不断变化的自然环境,以便于更好地生存下去。只有那些适应性强的个体才能在不断变化的自然环境中存活下来,并通过遗传机制将好的适应性特性传递给其后代。在这种遗传过程或适应环境过程中,个体可能发生变异,变异后可能具有更强的环境适应能力。这样,在进化过程中,生物群体将逐渐地产生适应生态环境的优良群体。受到Darwin的生物进化中适者生存、不适者淘汰的规律的启发,GA设计了一种迭代思想,当得到了一个初始解,而这个解与人们想要的精确的解相差很大时,把这个解通过某种方法一步一步地向精确解逼近,就像对高次方程求根一样,而每次迭代得到的解都比上一次得到的解更加接近于精确解。

GA 自从 20 世纪 60 年代被提出以来就得到了广泛应用,特别在函数优化、生产调度、模式识别、神经网络、自适应控制等领域,GA 更是发挥了重大的作用,大大提高了求解搜索问题的效率。GA 是近年来迅速发展起来的一种全新的随机搜索与优化算法,其基本思想是基于 Darwin 的进化论和 Mendel 的遗传学说。该算法由美国密执安大学教授 Holland 及其学生于 1975 年创建。此后,GA 的研究引起了国内外学者的密切关注。80 年代,GA 迎来了兴盛发展时期,无论是理论研究还是应用研究都成了十分热门的课题。1985 年,在美国召开了第一届 GA 国际会议(International Conference on Genetic Algorithms, ICGA),并且成立国际 GA 学会(International Society of Genetic Algorithms, ISGA),以后每两年举行一次。1989 年, Holland 的学生 D. E. Goldberg 出版了专著《搜索、优化和机器学习中的 GA》。该书总结了 GA 研究的主要成果,对 GA 及其应用作了全面而系统的论述。同年,美国斯坦福大学 Koza 教授基于自然选择原则创造性地提出了用层次化的计算机程序来表达问题的遗传程序设计(Genetic Programming, GP)方法,成功地解决了许多实际问题。在欧洲,从 1990 年开始隔年举办一次 Parallel Problem Solving from Nature 学术会议,其中 GA 是会议的主要内容之一。此外,以 GA 的理论基础为中心的学术会议还有 Foundations of Genetic Algorithms,该会议也是从 1990 年开始隔年召开一次。这些国际会议论文集集中反映了 GA 近些年来的最新发展和动向。1991 年, L. Davis 出版了《GA 手册》,其中包括了 GA 在工程技术和生活中的大量应用实例。

当前,科学技术正进入多学科互相交叉、互相渗透、互相影响的时代。生命科学与工程科学的交叉、渗透和相互促进就是近代科学技术发展中的一个相互交叉的典型例子。GA 的不断发展正体现了科学发展的这一特点和趋势。GA 也是当前“软计算”领域的一个重要研究课题,把 GA 与计算机程序结合起来的思想出现在 GA 应用中。Holland 把产生式语言和 GA 结合起来实现了分类系统。还有一些 GA 应用领域的研究者将类似于 GA 的遗传操作施加于树结构的程序上。遗传程序设计是借鉴生物界的自然选择和遗传机制,在 GA 的基础上发展起来的搜索算法,已成为进化计算的一个新分支。在标准 GA 中,由定长字符串(即问题的可行解)组成的群体借助于复制、交叉、变异等遗传操作不断进化找到问题的最优解或准优解。遗传程序设计运用 GA 的思想,常采用树的结构来表示计算机程序,由此解决实际问题。对于许多问题,包括人工智能和机器学习上的问题都可看作是编写一个计算机程序,即对特定输入产生特定输出的程序,实现程序归纳。所以说遗传程序设计提供了实现程序归纳的方法。近年来,遗传程序设计运用 GA 的思想自动生成计算机程序解决了许多问题,如预测、分类、符号回归和图像处理等。作为一种新技术,遗传程序设计与 GA 并驾齐驱。1992 年, Koza 发表了专著《遗传程序设计——基于自然选择法则的计算机程序设计》。1994 年,他又出版了《遗传程序设计(第二册)——可重用程序的自动发现》,深化了遗传程序设计的研究,使遗传程序设计自动化展现了新局面。有关 GA 的学术论文也不断在国际杂志《Artificial Intelligence》、《Machine Learning》、《Information Science》、《Parallel Computing》、《Genetic Programming and Evolvable Machines》、《IEEE Transactions on Neural Networks》、《IEEE Transactions on Signal Processing》和《电子学报》等国内外杂志上发表。

目前,关于 GA 理论的研究仍在持续,越来越多不同领域的研究人员致力于 GA 与其他科学相结合的研究和应用中。本书主要介绍 GA 及其在图像处理中的应用,并给出具体

的步骤和基于 MATLAB 的程序代码,以便于初学者学习、仿真和应用 GA 解决实际问题。

1.1.2 生物遗传与 GA 原理

GA 是模拟生物在自然环境下的遗传和进化过程而形成的一种自适应全局优化概率搜索算法。GA 是一种群体优化算法,即从多个初始解开始进行优化,每个解称为一个染色体(DNA),各个 DNA 之间通过竞争、合作、变异,不断进化,得到最优解。

1. 生物遗传

遗传是一种生物从其亲代继承特性和性状的现象。生物的遗传物质的主要载体是 DNA,其中基因是最主要的遗传物质,是控制生物性状的遗传物质的功能单位和结合单位。生物体父代与子代之间通过 DNA 来传递遗传信息。DNA 可以分成很多片段。对传递遗传信息来说,并不是每一段 DNA 都是有用的,其中有用的那些片段称为基因。基因在 DNA 中的位置为基因座。同一基因座的全部基因为等位基因。等位基因和基因座决定了 DNA 的特征,也决定了生物个体的特性。从 DNA 的表现形式看,有两种相应的表示模式:基因型和表现型。表现型是指生物个体表现出来的性状,而基因型则是指与表现密切相关的基因组成。同一基因型的生物个体在不同的环境条件下有不同的表现型。因此,表现型是基因型与环境相互作用的结果。生物的主要遗传方式是复制,是后代通过繁殖的方式从上一代获得与之基本一样的性状,使得它们之间有着相同的基因。但在复制过程中,由于受一些因素的影响,基因可能发生了变化,导致了后代与上一代在性状上产生差异,这也就是变异的原因之一。在进化算法中,可以复制字符串得到与之一样的表现型个体,也可以改变其中的字符获得与之完全不同的表现型个体。利用字符能够简单、明确地模仿遗传学中的基因。由一组字符可以构成一个字符串,它是 DNA 的最简单表示方法,字符排列方式不同就构成了不同的字符串,字符串所起的作用正是基因的作用。在 GA 中,DNA 对应的是一系列符号序列;在标准 GA 中,DNA 通常用 0、1 组成的位字符串表示,串上各个位置对应基因座,各位置上的取值对应等位基因。一定数量的基因个体组成基因种群,该集合内的个体数目称为种群的大小。种群中个体的数目称为种群的规模。生物在其延续生存的过程中,逐渐适应其生存环境,使得其品质不断得到改良,这种生命现象称为进化。度量某个物种对于生存环境的适应程度,即各个体对环境的适应程度称为适应度。对生存环境适应程度较高的物种将获得更多的繁殖机会,而对生存环境适应程度较低的物种,其繁殖机会相对较少,甚至会逐渐灭绝。

在生物进化过程中,涉及如下 6 种基本操作过程:

- (1) 选择。决定以一定的概率从种群中选择若干个体的操作(实现优胜劣汰)。
- (2) 复制。细胞在分裂时,遗传物质的 DNA 通过复制而转移到新产生的细胞中,新的细胞就继承了旧细胞的基因。
- (3) 交叉,又称基因重组。在两个 DNA 的某一相同位置处 DNA 被切断,其前后两串分别交叉组合形成两个新的 DNA。
- (4) 变异。在细胞进行复制时可能以很小的概率产生某些复制差错,从而使 DNA 发生某种变异,产生出新的 DNA,这些新的 DNA 表现出新的性状。
- (5) 编码。编码指表现型到基因型的映射。
- (6) 解码。解码指从基因型到表现型的映射。

2. GA 的基本原理

GA 是模拟生物进化过程的计算模型,是自然遗传学与计算机科学相互结合、相互渗透而形成的新的计算方法,是一种借鉴生物界自然选择和自然遗传机制的随机化搜索算法。GA 采纳了自然进化模型、自适应全局优化概率搜索算法。GA 从本质上讲是一个群体迭代过程,从一个任意初始(解)群体出发,根据优胜劣汰的原则,通过竞争、选择、繁殖、变异等类似生物遗传进化的作用,从而产生具有新性能、性能更为优良的下一代群体,即在每一代,根据问题域中个体的适应度高低进行选择,并借助遗传算子进行组合交叉和主客观变异,产生出代表新的解集的种群,逐代实现“适者生存和优胜劣汰”,演化产生出越来越好的解,直到满足优化准则为止。最后得到的末代个体经解码,生成近似最优解。

1.1.3 GA 与传统方法比较

一个简单的求函数最大值的优化问题(求函数最小值也类似),一般可描述为带约束条件的一个数学规划模型

$$\begin{cases} \max & f(X) \\ \text{s. t.} & X \in R, \quad R \subseteq U \end{cases} \quad (1.1)$$

式中, $X=[x_1, x_2, \dots, x_n]'$ 为决策变量, $f(X)$ 为目标函数, U 为基本空间, R 是 U 的一个子集。

满足约束条件的解称为可行解,集合 R 表示由所有满足约束条件的解所组成的一个集合,称为可行解集。它们之间的关系如图 1.1 所示。



图 1.1 最优化问题的可行解及可行解集合

对于式(1.1)的最优化问题,目标函数和约束条件种类繁多,有线性的、非线性的、连续的、离散的、单峰值的、多峰值的等。随着对 GA 研究的不断深入,人们逐渐认识到在很多复杂情况下要想完全精确地求出其最优解一般是不可能的,也是不现实的,因而求出其近似最优解或满意解是人们主要研究的问题之一。

求最优解或近似最优解的传统方法主要有解析法、随机法和穷举法。解析法主要包括爬山法和间接法以及 GA;随机法主要包括导向随机方法和盲目随机方法;而穷举法包括完全穷举法、回溯法、动态规划法和限界剪枝法。对于求解此类问题,GA 与一般传统方法有着本质的区别,这些区别包括:

(1) GA 与启发式算法的区别。启发式算法是指通过寻求一种能产生可行解的启发式规则,找到问题的最优解或一个近似最优解。该方法求解问题的效率较高,但它对每一个优化问题必须找出其特有的启发式规则,而该规则一般无通用性,因此该法可能不适合其他问题。GA 采用的不是确定性规则,而是强调利用概率转换规则来引导搜索过程。

(2) GA 与爬山法的区别。爬山法是直接法、梯度法和 Hessian 法的通称。该方法首先在最优解可能存在的范围内选择一个初始点,然后通过分析目标函数的特性,由初始点移

到一个新的点,再继续这个过程。爬山法的搜索过程是确定的,通过产生一系列的点收敛到最优解(有时是局部最优解),而 GA 的搜索过程是随机的,它产生一系列随机种群序列。二者的主要区别归纳如下:

① 爬山法的初始点仅有一个,由决策者给出;而 GA 的初始点有多个,是随机产生的。

② 通过分析目标函数的特性可知,爬山法由上一点产生一个新的点;而 GA 通过遗传操作,在当前的种群中经过交叉、变异和选择产生下一代种群。

对同一优化问题,GA 所使用的机时比爬山法所花费的机时要多,但 GA 能够处理一些爬山法所不能解决的复杂的优化问题。

(3) GA 与穷举法的区别。穷举法是对解空间内的所有可行解进行搜索,但通常的穷举法并不是完全穷举法,即不是对所有解进行尝试,而是有选择地尝试,如动态规划法、限界剪枝法。对于一些特定问题,穷举法也可能表现出很好的性能。在一般情况下,完全穷举法简单易行,但求解效率太低;动态规划法、限界剪枝法则鲁棒性不强。相比较而言,GA 具有较高的搜索能力和极强的鲁棒性。

(4) GA 与盲目随机法的区别。与上述搜索方法相比,盲目随机搜索法有所改进,但它的搜索效率仍然不高。一般而言,只有解在搜索空间中形成紧致分布时,它的搜索才有效;而 GA 作为导向随机搜索方法,是对一个被编码的参数空间进行高效搜索。图 1.2 为传统算法和 GA 对比示意图。




图 1.2 传统算法和 GA 对比示意图

经过上面的探讨,可以看到 GA 与更多的传统方法和优化方法在本质上有着不同之处,主要归纳为如下 4 点:

- (1) GA 搜索种群中的点是并行的,而不是单点。
- (2) GA 并不需要辅助信息或知识,只需设计搜索方向的目标函数与对应的适应度。
- (3) GA 使用概率变换规则,而不是确定的变换规则。
- (4) GA 使用编码参数集,而不是自身的参数集(除了在实值个体中使用)。

1.1.4 GA 的特点和优缺点

1. GA 的特点

- (1) GA 是一类随机优化算法,但它不是简单的随机搜索,而是有效利用已有的信息

来搜索那些有希望改善解质量的串。类似于自然进化,GA 通过作用于 DNA 上的基因,寻找好的 DNA 来求解问题。与自然界相似,GA 对待求解问题本身一无所知,它所需要的仅是对算法所产生的每个个体进行评价,并基于适应度值来改变个体的字符串,使适用性好的字符串比适应性差的字符串有更多的繁殖机会。

(2) GA 利用简单的编码技术和繁殖机制来表现复杂的现象,提供了一种求解复杂系统优化问题的通用框架,它不依赖于问题具体的领域,对问题的种类有很强的鲁棒性,能够解决非常困难的问题。特别是由于它不受搜索空间的限制性假设的约束,不必要求诸如连续、导数存在和单峰等假设,以及其固有的并行性,在最优化、机器学习和并行处理方面等得到越来越广泛的应用。

(3) GA 的本质是并行性。

① GA 从问题解的串集开始搜索,而不是从单个解开始。这是 GA 与传统优化算法的极大区别。传统优化算法是从单个初始值迭代求最优解,容易误入局部最优解。GA 从串集开始搜索,覆盖面大,利于全局择优。

② GA 内含并行性。采用种群方式组织搜索,可同时搜索空间的多个区域,并相互交流信息,能以较小的计算获得较大的收益。

(4) GA 基本上不用搜索空间的知识或其他辅助信息,仅用适应度函数值来评价,在此基础上进行遗传操作。适应度函数不仅不受连续可微的约束,而且其定义域可以任意设定。这一特点使得 GA 的应用范围得到极大扩展。

(5) GA 不是采用确定性规则,而是采用概率的变迁规则来指导它的搜索方向,具有自组织、自适应和自学习性。GA 在利用进化过程获得的信息自行组织搜索时,适应度大的个体具有较高的生存概率,并获得更适应环境的基因结构。

(6) GA 能够直接应用。对于给定问题,GA 可以产生许多潜在解,而最终解可以直接由使用者指定,所以 GA 通用性高,应用范围广。

(7) GA 擅长解决的问题是全局最优化问题。例如,解决时间表安排问题就是它的一个特长,很多安排时间表的软件都使用 GA。GA 还经常被用于解决实际工程问题。跟传统的爬山算法相比,GA 能够跳出局部最优而找到全局最优点。GA 允许使用非常复杂的适应度函数,并可以对变量的变化范围加以限制。而如果是传统的爬山算法,对变量范围进行限制意味着需要处理更复杂的求解过程。

2. GA 在解决优化问题过程中的特点

解决函数(或目标)的优化问题的方法主要有解析法和数值计算法。利用解析法来求解函数优化问题,需要先对目标函数和约束函数求导,再利用函数极值的条件求出函数的极值点,最后将极值点作为函数优化问题的解。由于解析法需要利用函数导数的解析表达式,因此只适用于解决简单的函数优化问题。数值计算法主要有线性规划中的单纯形法,非线性规划中的坐标轮换法、梯度法、拟牛顿法、共轭梯度法、序列二次规划法和几何规划与动态规划中的一些方法。这些数值计算方法大部分需要利用函数的导数信息。因此,这类方法只能应用于函数连续、可导的优化问题,所以其应用领域受到一定的限制。另外,由于数值计算类优化方法大多利用导数信息来搜索优化方向,因而不可避免地会收敛于局部优化解。GA 只需函数值的信息,不需要设计空间或函数的连续,因而适合于求解各类函数优化问题。GA 能在设计空间的较大范围内寻优,因而更有可能获得全局优化解。与

其他数值计算方法相比, GA 的特点归纳如下:

(1) GA 在适应度函数选择不当的情况下有可能收敛于局部最优, 而不能达到全局最优。

(2) 初始种群中的个体数目很重要。若初始种群数目过多, 算法会占用大量系统资源; 若初始种群数目过少, 算法很可能忽略掉最优解。

(3) 对于每个解, 一般根据实际情况进行编码, 这样有利于编写变异函数和适应度函数。

(4) 在已编码的 GA 中, 每次变异的编码长度直接影响 GA 的效率。若变异代码长度过长, 变异的多样性会受到限制; 若变异代码过短, 变异的效率会非常低下, 选择适当的变异长度是提高效率的关键。

(5) 交叉概率和变异概率的选取对 GA 的影响非常大。它直接影响着待优化问题的收敛速度和最终解的质量。对于任何一个具体的优化问题, 调节 GA 的参数可能会有利于更好、更快地收敛, 这些参数包括个体数目、交叉概率和变异概率。例如, 太大的变异率会导致丢失最优解, 而过小的变异率会导致算法过早地收敛于局部最优点。对于这些参数的选择, 现在还没有实用的上下限。对于交叉概率和变异概率的在线调节也并非易事。近 10 年来已出现一些在线调节交叉概率和变异概率的自适应算法。已有的研究表明, 与基于传统启发式知识的控制算法相比, 采用模糊逻辑控制的方法调节交叉概率和变异概率具有更优越的性能。

(6) 对于动态数据, 用 GA 求最优解比较困难, 因为 DNA 种群很可能过早地收敛, 而对以后变化了的数据不再产生变化。对于这个问题, 研究者提出了一些方法增加基因的多样性, 从而防止过早地收敛。其中一种是所谓的触发式超级变异, 就是当 DNA 群体的质量下降(彼此的区别减少)时增加变异概率; 另一种叫随机外来 DNA, 是偶尔加入一些全新的随机生成的 DNA 个体, 从而增加 DNA 的多样性。

(7) 选择操作很重要, 但交叉和变异的重要性存在争议。一种观点认为交叉比变异更重要, 因为变异只是保证不丢失某些可能的解; 而另一种观点则认为交叉过程的作用只不过是在种群中推广变异过程所造成的更新, 对于初期的种群来说, 交叉几乎等效于一个非常大的变异率, 而这么大的变异很可能影响进化过程。

(8) GA 很快就能找到良好的解, 即使是在很复杂的解空间中。

(9) GA 并不一定总是最好的优化策略, 优化问题要具体情况具体分析。所以在使用 GA 的同时, 也可以尝试与其他算法相结合, 互相补充。

(10) GA 不能解决那些“大海捞针”的问题, 即没有一个确切的适应度函数表征个体好坏的问题, 使得算法的进化失去导向。

(11) 适应度函数对于 GA 的速度和效果很重要。

3. 与传统的搜索算法相比较, GA 的特点

(1) GA 以编码形式工作, 把问题的参数集表示成个体, 并以编码的形式运行, 而不是对参数本身进行求解。GA 进行优化操作的对象是所有优化变量的编码, 不是直接对优化变量本身进行搜索寻优。

(2) GA 的每一步是从解空间中的一个解群向另一个解群搜索, 而不是从一个解点向另一个解点探索, 可以并行搜索多个峰值而不是一个点。GA 具有运算并行性, 它可以在

复杂的搜索空间内同时评价多个点,这样有利于在多值空间寻找全局最优解。

(3) GA 在搜索过程中只利用目标函数值,而不需要目标函数导数或其他任何辅助信息。

(4) 在解空间的搜索转移过程中,GA 采用概率性转移规则,而不是确定性转移规则。

(5) GA 与进化策略、进化程序设计被认为是进化算法的 3 个主要算法。由于 GA 的并行性,使得 GA 与计算机的结合显示出了巨大的优越性。GA 强调个体的运算;进化策略强调个体水平的行为变化;进化程序设计强调种类水平的行为变化。可以认为进化策略和进化程序设计都是 GA 功能的扩展和补充。

GA 的这些特点决定了它较为适合于维数高、总体很大、环境复杂、问题结构不十分清楚的情况,机器学习就属于这类情况。一般的学习系统要求具有随时间推移逐步调整有关参数或改变自身结构以更加适应其环境、更好地实现目标的能力。由于其多样性与复杂性,通常难以建立完善的理论以指导整个学习过程,从而使传统寻优技术的应用受到限制,而这恰好能使 GA 发挥其长处。

4. GA 的优点

(1) GA 的最大优点是算法基本结构比较简单,并且对搜索空间(目标函数的性质)不加任何限制(不要求连续性、可微性,不限于单峰等)。GA 直接对结构对象进行操作,不存在求导和函数连续性的限定;具有内在的隐并行性和更好的全局寻优能力;采用概率化的寻优方法,能自动获取和指导优化的搜索空间,自适应地调整搜索方向,不需要确定的规则。正因为如此,目前许多学科的研究人员都开始探索采用这种技术来解决各自学科中长期未能很好解决的优化问题。这些问题的特点是目标函数或约束条件大都是非线性、不可微的,甚至是不连续的,传统的数学寻优方法无法有效地求解得到满意解,而 GA 却可以给人们带来令人满意的结果。

(2) GA 搜索时使用评价函数启发,过程简单。GA 对所求解的优化问题没有太多的数学要求。由于 GA 的进化特性,搜索过程中不需要问题的内在性质,对于任意形式的目标函数和约束,无论是线性的还是非线性的,离散的还是连续的,都可处理。

(3) GA 使用概率机制进行迭代,具有随机性。搜索从群体出发,具有潜在的并行性。进化算子的各态历经性使得 GA 能够非常有效地进行概率意义的全局搜索。

(4) GA 具有可扩展性,容易与其他算法结合。GA 对于各种特殊问题可以提供极大的灵活性来混合构造领域独立的启发式,从而保证算法的有效性。

5. GA 的缺点

(1) 编码不规范和编码表示的不准确性。GA 的编程实现比较复杂,首先需要对问题进行编码,找到最优解之后还需要对问题进行解码。目前尚无一套完善的编码准则作为指导思想,在解决实际问题时需要不断尝试各种编码方法,这样很容易造成一些误差。有些实际优化问题的约束条件很复杂,仅仅依靠 GA 编码很难把它们表述出来。

(2) 三个算子的实现有许多参数,并且这些参数的选择严重影响解的品质,而目前这些参数的选择大部分是依靠经验。

(3) GA 容易出现过早收敛。

(4) GA 没能及时利用网络的反馈信息,导致 GA 的搜索速度比较慢,要得到较精确

的解需要较多的训练时间。

(5) 单一的 GA 编码不能全面地将优化问题的约束表示出来。考虑约束的一个方法是对不可行解采用阈值, 由此使得运算时间增长。

(6) GA 对初始种群的选择有一定的依赖性, 可结合一些启发算法进行改进。

(7) GA 对算法的精度、可信度、计算复杂性等方面, 还没有有效的定量分析方法。

GA 作为一种非确定性的、拟自然算法, 为复杂系统的优化提供了一种新的思路, 并且实践证明了它的显著效果。在现在研究中, GA 已经不能很好地解决大规模计算量问题, 它很容易陷入“早熟”。常用混合 GA、合作型协同进化算法等来替代, 这些算法都是 GA 的衍生算法。尽管 GA 在很多领域具有广泛的应用价值, 但它仍存在一些问题, 如 GA 很多机制和现象还缺少理论的指导, 这都需要对 GA 做进一步的研究。

1.1.5 GA 中的一些术语

由于 GA 是自然遗传学和计算机科学相互结合渗透而成的新的计算方法, 因此 GA 中经常使用自然进化中有关的一些基本用语。了解这些用语对于讨论和应用 GA 是十分必要的。本节将介绍 GA 的一些基本术语, 主要包括: 个体、种群、代、父辈和子辈、多样性、适应度函数、适应度值和最佳适应度值。

(1) 个体。一个个体可以是施加适应度函数的任意一点。个体的适应度函数值就是它的得分或评价。例如, 对于适应度函数 $f(x_1, x_2, x_3) = (2x_1 + 1)^2 + (3x_2 + 4)^2 + (x_3 - 2)^2$, 则向量 $[2, -3, 1]$ 是一个个体, 向量的维数是问题中变量的个数。个体 $[2, -3, 1]$ 的适应度值(得分)是 $f[2, -3, 1] = 51$ 。

个体有时又称为基因组或 DNA 组, 个体的向量项称为基因。

(2) 种群与代。所谓种群, 是指由个体组成的一个数组或矩阵。例如, 若个体的长度是 100, 适应度函数中变量的个数为 3, 可以将这个种群表示为一个 100×3 的矩阵。相同的个体在种群中可以出现不止一次。例如, 个体 $[2, -3, 1]$ 就可以在数组的行中出现多次。每一次迭代, GA 都对当前种群执行一系列的计算, 产生一个新的种群。通常把每一个后继的种群称为新一代。

(3) 父辈和子辈。为了生成下一代, GA 在当前种群中选择某些个体, 称为父辈, 并且使用它们来生成下一代中的个体, 称为子辈。在典型情况下, 该算法更可能选择那些具有较大适应度值的父辈。

(4) 多样性。多样性或差异涉及一个种群的各个个体之间的平均距离。若平均距离大, 则种群具有高的多样性; 否则, 其多样性低。多样性是 GA 必不可少的本质属性, 这是因为它能使 GA 搜索一个比较大的解的空间区域。

(5) 适应度函数。所谓适应度函数, 就是想要优化的函数。对于标准优化算法而言, 这个函数称为目标函数。GA 总是试图寻找适应度函数的最小值。可以将适应度函数编写为 MATLAB 中的一个 M 文件, 作为输入参数传递给 GA 函数。

(6) 适应度值和最佳适应度值。个体的适应度值就是该个体的适应度函数的值。由于该工具箱总是查找适应度函数的最小值, 所以一个种群的最佳适应度值就是该种群中任何个体的最小适应度值。

表 1.1 为自然遗传学和人工 GA 中所使用的基础用语的对应关系。