

基于改进的蝗虫优化算法的红细胞供应预测方法



刘奇¹ 陈红梅² 罗川³

1 西南交通大学唐山研究生院 河北唐山 063000

2 西南交通大学信息科学与技术学院 成都 611756

3 四川大学计算机学院 成都 610065

(success467@163.com)

摘要 当前国内“血荒”问题比较严峻,血站与用血单位之间存在着血液供不应求的现象。针对这个问题,提出了一种基于改进的蝗虫优化算法的 LSTM 预测方法,用于对未来的红细胞供应情况进行预测,为血站工作人员在制定采血计划以及制备计划时提供有效的指导。该预测模型通过使用长短期记忆网络(Long-Short Term Memory Network,LSTM)来捕捉历史红细胞库存数据之间的潜在规律,以达到对未来的供应情况进行预测的效果。首先,针对蝗虫优化算法容易陷入局部最优、收敛速度较慢的问题,通过加入基于折射原理的反向学习机制与混沌映射,加快蝗虫优化算法的收敛速度,使其具备更强的搜索能力。其次,为提高 LSTM 的预测性能,将改进的蝗虫优化算法与 LSTM 相结合,并使用某地区的红细胞库存真实数据作为实验数据,用于验证改进的 LSTM 预测模型的性能。与标准 LSTM 相比,所提方法的 MAE,MAPE, RMSE 分别降低了 39.8278, 1.10%,55.8191。实验结果证明,提出的方法具有较高的可靠性。

关键词:蝗虫优化算法;反向学习;混沌映射;长短期记忆网络;红细胞供应预测

中图分类号 TP389

Method for Prediction of Red Blood Cells Supply Based on Improved Grasshopper Optimization Algorithm

LIU Qi¹, CHEN Hong-mei² and LUO Chuan³

1 Graduate School of Tangshan, Southwest Jiaotong University, Tangshan, Hebei 063000, China

2 School of Information Science and Technology, Southwest Jiaotong University, Chengdu 611756, China

3 College of Computer Science, Sichuan University, Chengdu 610065, China

Abstract At present, the problem of blood supply shortage is quite serious. There exists the phenomenon that short supply happen between blood stations and institutions that use blood. Aiming at such a problem, the LSTM prediction method based on the improved grasshopper optimization algorithm(GOA) is proposed in order to predict red blood cells supply in the future and provide effective guidance for workers in making blood collection plan and preparation plan. By using LSTM to capture the underlying patterns between the historical data, the effect of predicting the future can be achieved. There are two parts of work. Firstly, aiming at the problem that the conventional GOA is easy to fall into local optimum and has a slower convergence speed, the model of refracting opposite-based learning and chaotic mapping are introduced to GOA so as to improve the global exploration capability. Secondly, in order to improve the accuracy of LSTM, it is combined with the improved GOA and evaluate the performance of the improved LSTM model by using the real data of red blood cells supply in a certain area. Comparing to the conventional LSTM, the MAE, MAPE, RMSE are reduced by 39.8278, 1.10%, 55.8191, respectively. The experimental results show that the proposed method has higher reliability.

Keywords Grasshopper optimization algorithm, Opposite-based learning, Chaotic mapping, Long short-term memory, Prediction of red blood cells supply

收稿日期:2020-06-01 返修日期:2020-08-26 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61976182,61572406,6207022096);四川省国际科技创新合作重点项目(2019YFH0097);四川省科技厅应用基础研究计划项目(2019YJ0084)

This work was supported by the National Natural Science Foundation of China(61976182,61572406,6207022096), Key Program for International S&T Cooperation of Sichuan Province(2019YFH0097) and Applied Basic Research Programs of Science and Technology Department of Sichuan Province(2019YJ0084).

通信作者:陈红梅(hmchen@swjtu.edu.cn)

1 引言

血液是一种极其珍贵的医疗资源,在临床治疗中起到至关重要的作用^[1]。近年来,我国医疗卫生体系不断健全、完善,临床用血的需求量也在快速增长。由于血液在采集完成之后要制备成各种成分的血液制品,各种血液制品的保质期又各不相同,这加剧了血液管理的难度,给血站工作人员的工作带来了极大的挑战。众所周知,临床用血的主要来源是采血与后期血站的加工。如果采血量不足,则会直接造成临床供血不足。就目前的情况而言,从献血者到采血点献血开始,到血液制品送达临床被输注到病人体内,这个过程的一个环节都有可能由于工作人员操作不当、过量使用等原因造成的血液浪费,这都会直接或间接地影响到血液库存量^[2]。除此之外,国内的用血量一直处于上升的趋势^[3-5],掌握实际情况有助于工作人员制定合理的计划以应对突发情况。在制定采血计划以及制备计划时,如果能够准确地预测血站未来可能的出库量,则对后期血站工作者在制定采血计划以及制备计划方面有很好的指导作用。

血液供应预测主要作为血站工作人员在制定日常采血计划以及制备计划时的参考,对结果的精度要求较高。影响血液供应情况的因素有很多,如日常采血情况、血液的报废情况等。在预测方面常用的方法有线性回归方法和机器学习方法。但是,在处理非线性数据时,线性回归方法往往表现较差,难以拟合非线性数据,以至于不能给出较为准确的预测结果;特别是在处理长时间序列时,难以捕捉数据之间的潜在关系。与之相比,机器学习方法的表现就比较高效。在机器学习方法中,最常用的是神经网络模型。目前,已有诸多学者、研究人员在血液库存预测方面取得了成果。Khalidi 等构建了 ANN 人工神经网络并将其应用于血液需求预测,从而完成对红细胞、血浆、血小板需求的预测^[6]。Fanoodi 等使用基于 ANN 人工神经网络与 ARIMA 自回归综合移动平均模型对血小板需求进行预测,降低了临床血小板需求量的不稳定性^[7]。Fortsch 等对纽约的一个血液中心 2006 年 1 月至 2012 年 12 月的每日需求数据进行了分析,使用了多种方法对血液需求进行预测,并提出了 Box-Jenkins 方法,其为最适合预测血液需求的方法^[8]。Zheng 等通过对江西省血液中心 2005—2016 年每个月的临床用血的数据进行了分析,建立了 LSTM 预测模型用于预测未来的临床用血需求量^[9]。Nandi 等对英格兰地区的红细胞需求情况进行了预测,提出了一种基于最小均方误差的线性预测方法,并使用该地区 2005 年 2 月 1 日至 2011 年 7 月 31 日共 6.5 年的数据来验证预测方法的高效性^[10]。

在处理非线性数据方面,神经网络的效果比传统回归模型显著得多^[11],且 LSTM 在处理长时间序列时的优势更为突出^[12]。但是 LSTM 的参数通常由经验确定^[13],这往往会使得 LSTM 难以达到预期效果。

群智能优化算法是一种基于随机的优化算法,是学者们受大自然的一系列现象的启发而得出的成果,常见的优化算法有遗传算法^[14](Genetic Algorithm,GA)、鲸鱼优化算法^[15]

(Whale Optimization Algorithm,WOA)、粒子群优化算法^[16](Particle Swarm Optimization Algorithm,PSO)、蝗虫优化算法^[17](Grasshopper Optimization Algorithm,GOA)、蝙蝠优化算法^[18](Bat Algorithm,BA)等。这类优化算法由于具有收敛速度快、精度高等特点,已被广泛应用到实际生活中。

在此基础上,本文提出了一种基于群智能优化算法的 LSTM 预测模型,将混沌映射与基于折射原理的反向学习机制应用于蝗虫优化算法对其进行改进,并将改进的蝗虫优化算法与 LSTM 相结合,构建混合预测模型。本文以某地区的真实红细胞库存情况为实验数据,验证了该预测模型的预测性能。实验结果证明,该模型在红细胞供应量预测方面具有高效性。

2 相关理论

2.1 LSTM

LSTM 是在循环神经网络(Recurrent Neural Network,RNN)的基础上发展而来的一种重要的改进模型^[19]。与 RNN 不同的是,LSTM 可以处理长时间序列,学习时间序列之间的长期依赖关系。另外,LSTM 还解决了 RNN 难以避免的梯度爆炸问题。LSTM 内部具有重复模块链结构,也就是 4 道门,分别是遗忘门、输入门、更新门、输出门。LSTM 的计算过程如下:

$$f_t = \sigma(W_{hf}H_{t-1} + W_{xf}X_t + b_f) \quad (1)$$

$$i_t = \sigma(W_{hi}H_{t-1} + W_{xi}X_t + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(W_{hc}H_{t-1} + W_{xc}X_t + b_c) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{c}_t \quad (4)$$

$$O_t = \sigma(W_{ho}H_{t-1} + W_{xo}X_t + b_o) \quad (5)$$

$$H_t = O_t \odot \tanh(C_t) \quad (6)$$

其中, f_t 表示 t 时刻遗忘门的输出结果; i_t 表示 t 时刻输入门的处理结果; \tilde{c}_t 表示上一个时刻的细胞状态; C_t 表示最新时刻的细胞状态; O_t 代表输出门的处理结果; H_t 表示 t 时刻的输出值; $W_{hf}, W_{hi}, W_{hc}, W_{ho}$ 分别指遗忘门、输入门、更新门、输出门中连接输入值的权重矩阵,并且 $W_{xf}, W_{xi}, W_{xc}, W_{xo}$ 分别指连接隐藏层输出值的权重矩阵, b_f, b_i, b_c, b_o 分别指偏置矩阵, σ 和 \tanh 分别为 sigmoid 函数和 tanh 函数。

2.2 蝗虫优化算法

蝗虫优化算法是一种群智能优化算法,由 Saremi 等提出,由于该算法的全局寻优能力较强,现已被广泛应用于结构优化设计^[20]。GOA 通过模拟蝗虫的幼虫与成虫的群居行为,来对蝗虫之间的斥力、吸引力进行数学建模。在 GOA 中,第 i 个蝗虫的位置可以表示为:

$$X_i = S_i + G_i + A_i \quad (7)$$

其中, X_i, S_i, G_i 分别表示种群中第 i 个蝗虫的位置、在种群中受到的影响力、重力大小。个体在种群中受到的影响力可以由下式表示:

$$S_i = \sum_{j=1, j \neq i}^n s(d_{ij}) \widehat{d}_{ij} \quad (8)$$

$$s(r) = f e^{-r} - e^{-r} \quad (9)$$

$$d_{ij} = |x_i - x_j| \quad (10)$$

$$\widehat{d}_{ij} = \frac{\mathbf{x}_i - \mathbf{x}_j}{d_{ij}} \quad (11)$$

其中,式(9)定义了蝗虫在种群中受到的影响力的强度, d_{ij} 表示第*i*个蝗虫与第*j*个蝗虫之间的距离, \widehat{d}_{ij} 表示第*i*个蝗虫至第*j*个蝗虫的一条单位向量, f 和 l 分别为蝗虫在种群中受到的影响力的强度和吸引力的长度范围, \mathbf{x}_i 和 \mathbf{x}_j 分别代表第*i*个蝗虫与第*j*个蝗虫的位置。

$$\mathbf{G}_i = -g \widehat{\mathbf{e}}_g \quad (12)$$

其中, g 指重力常量, $\widehat{\mathbf{e}}_g$ 是一条指向地球中心的单位向量。

$$\mathbf{A}_i = u \widehat{\mathbf{e}}_w \quad (13)$$

其中, u 是一个偏移常量, $\widehat{\mathbf{e}}_w$ 是一条关于风向的单位向量。

根据以上公式,第*i*个蝗虫的位置表示为:

$$\mathbf{X}_i = \sum_{j=1, j \neq i}^n s(|\mathbf{x}_j - \mathbf{x}_i|) \frac{\mathbf{x}_j - \mathbf{x}_i}{d_{ij}} - g \widehat{\mathbf{e}}_g + u \widehat{\mathbf{e}}_w \quad (14)$$

为了更准确地对蝗虫种群的行为正进行数学建模,算法最终可以描述为:

$$\mathbf{X}_i^d = c_1 \left\{ \sum_{j=1, j \neq i}^n c_2 \frac{ub_d - lb_d}{2} s(|\mathbf{x}_j^d - \mathbf{x}_i^d|) \frac{\mathbf{x}_j^d - \mathbf{x}_i^d}{d_{ij}} \right\} + \widehat{\mathbf{T}}_d \quad (15)$$

其中, ub_d 和 lb_d 分别表示算法在第*d*维度的上界和下界, $\widehat{\mathbf{T}}_d$ 表示在第*d*维度时蝗虫群的目标位置, c_1 和 c_2 是控制种群中个体的搜索能力的重要参数。在标准GOA中,参数*c*以线性递减的方式更新。

$$c = c \max + l \frac{c \max - c \min}{L} \quad (16)$$

其中, $c \max$, $c \min$ 分别是最大值和最小值, l 指当前的迭代次数, L 是迭代次数的最大值。

2.3 基于折射原理的反向学习机制

反向学习机制的主要思想是,在随机初始化种群的情况下,很难确定这个种群中是否存在距离最优解决方案最近的解,且在很多情况下第一代种群往往较差^[21],如果我们从现有的解决方案相反的方向进行搜索,也就是同时在当前点与反向点中进行搜索,可能会提高得到相对较优的结果的可能性^[22]。OBL(Opposition-Based Learning)的定义如下:

$$X_i^* = a_i + b_i - x_i, i = 1, \dots, n \quad (17)$$

其中, $X(x_1, \dots, x_n)$ 是一个在区间 $[a_i, b_i]$ 上的*n*维度的真实值, x_i^* 是 x_i 的反向解。

光的折射定律指,当光从真空倾斜到另一种介质中时,折射光、入射光和法线会在同一个平面上。此时,折射角小于入射角,并且随着入射角的增大(或减小),折射角也会增大(或减小)^[23]。其中,入射角与折射角有以下关系:

$$n = \frac{\sin \varphi_1}{\sin \varphi_2} \quad (18)$$

其中, φ_1 和 φ_2 分别是光的入射角与折射角, n 即为入射角与折射角的比值。

将光的折射定律与反向学习机制结合之后,可以表示为:

$$\frac{\sin \varphi_1}{\sin \varphi_2} = \frac{a+b-x}{x^* - \frac{a+b}{2}} * \frac{h^*}{h} \quad (19)$$

令 $k = h^* / h$,则式(19)可表示为:

$$kn = \frac{a+b-x}{x^* - \frac{a+b}{2}} \quad (20)$$

用 x 表示 x^* ,则上述公式可以转换为:

$$x^* = \frac{a+b}{2} + \frac{a+b-x}{2kn} - \frac{x}{kn} \quad (21)$$

式(21)在高维空间中可以表示为:

$$x_{i,j}^* = \frac{a_j + b_j}{2} + \frac{a_j + b_j - x_{i,j}}{2kn} - \frac{x_{i,j}}{kn} \quad (22)$$

其中, a_i 和 b_i 分别为当前种群中第*j*维度的最大值与最小值; $x_{i,j}$ 和 $x_{i,j}^*$ 分别指当前种群中的蝗虫位置与其反向位置。

2.4 混沌映射

一般来说,混沌是一种具有确定性、随机性的方法^[24]。在一个混沌系统中,看似随机的振荡现象其实都是由非线性数据作用的结果,并且这与系统外部动量的发生没有关系。通过混沌映射,可以在指定区域内生成元素并确保不重复^[25]。在混沌映射中,三次映射的周期性分布间隔较优,其计算式描述如下:

$$\begin{cases} x_{n+1} = 4x_n^3 - 3x_n \\ -1 < x_0 < 1 \end{cases} \quad (23)$$

当初始值不为0时,可以通过上述公式生成混沌序列。

3 基于改进的蝗虫优化算法的LSTM预测模型

标准GOA在解决复杂的优化问题方面可以展示出较好的效果,但是对算法性能影响较大的是收敛因子*c*,收敛因子的变化会影响算法是否能够找到最优解决方案。此外,蝗虫种群的初始位置通常不会与最优位置距离特别近,如果种群的多样性不够丰富,那么会增加算法在后期迭代过程中寻找最佳位置的难度。

为解决以上问题,我们引入基于折射原理的反向学习机制与混沌方法来改进蝗虫优化算法,然后将改进的蝗虫优化算法与LSTM结合,以构建混合预测模型。

3.1 改进的蝗虫优化算法

在GOA中,每一个蝗虫的初始位置通常是随机确定的,在后期的迭代搜索过程中,所有搜索个体会不断靠近最优位置直至算法趋于收敛。如果蝗虫的初始位置距离最优位置较近,那么算法将会很快进入收敛状态。但是在很多情况下,初始种群的位置并不会与最优位置距离特别近,这时如果种群的多样性足够丰富,那么找到最佳位置的可能性就会提高。因此,本文引入基于折射原理的反向学习机制来改善蝗虫种群的多样性,以增加蝗虫种群搜索到最优位置的可能性^[26]。

如式(15)所示,GOA分别通过更新 c_1 和 c_2 来控制算法的探索与开发能力、缩小搜索个体的吸引力以及排斥力,以使算法整体趋于收敛。其中, c_1 对种群的探索与开发有着至关重要的作用, c_2 会调整每一个搜索个体的吸引力和排斥力,使算法逐渐趋于收敛。在算法迭代的初期,其收敛能力较差。另外,对于蝗虫种群的初始化以及迭代过程的更新,我们很难保证当前种群中的个体是否都是向着最优的方向搜索,因此还需要进一步丰富种群的多样性以提高搜索全局最优解的可能性。这里通过引入混沌方法来改进收敛因子的

更新过程,如式(18)所示。

基于折射原理的反向学习机制的蝗虫优化算法(Improved Grasshopper Optimization Algorithm, IGOA)的主要过程如下:

- 1)初始化 IGOA 的相关参数,如种群大小、维度、参数 c 的最大值和最小值、迭代次数;
- 2)初始化蝗虫种群 X ,计算个体适应度,根据个体适应度值确定当前种群最优个体 target;
- 3)计算 X 的反向种群 X_oppo ;
- 4)从 X, X_oppo 中选择 n 个较优的个体组成新的种群,并计算新种群的适应度值;
- 5)比较种群中每个个体与 target 的适应度值,如果当前个体优于 target,则更新 target 为当前个体;
- 6)若算法达到最大迭代次数或满足停止条件,则执行步骤 7),否则返回步骤 3);
- 7)输出种群最优值。

3.2 基于改进的蝗虫优化算法的 LSTM 预测模型

本文通过将改进的 GOA 和 LSTM 模型相结合,提出了 IGOA-LSTM 算法,并将其用于预测血液供应情况。预测模型的流程如图 1 所示。

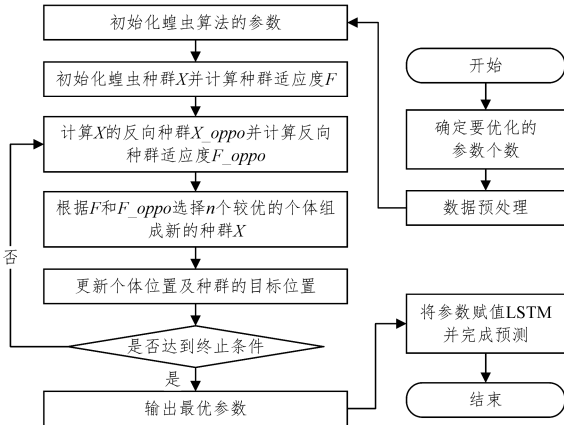


图1 IGOA-LSTM流程图

Fig. 1 Flow chart of IGOA-LSTM

本文模型的执行步骤如下。

- 1)确定要优化的参数个数。本文通过改进的蝗虫优化算法来优化 LSTM 的参数,因此每个蝗虫个体的维度需要与要优化的参数个数一致。
- 2)数据预处理。如果一组数据不属于正态分布或者不近似于正态分布,那么在这种情况下训练完成的模型的结果总是不尽人意。为了避免这一情况,需要对数据进行预处理操作,其计算式如下:

$$d = \frac{x - m}{s} \quad (24)$$

其中, x 为原始数据序列, m 和 s 分别为序列的平均值和标准差, d 为处理后的序列。

- 3)初始化模型的相关参数。具体包括种群大小、最大迭代次数、收敛因子的最大值与最小值,以及 LSTM 的最大迭代次数和丢弃率。
- 4)初始化种群 X 并计算种群适应度 F 。按照种群规模以

及个体维度初始化蝗虫的种群 $X_i (i=1, \dots, n)$,并在指定范围内生成蝗虫个体 $(time_step, lr, node1, node2)$, $time_step$ 是时间步子, lr 是 LSTM 的学习率, $node1$ 和 $node2$ 分别为 LSTM 的第一层隐藏层、第二层隐藏层的神经元个数。种群初始化完毕之后计算蝗虫个体的适应度值 $F_i (i=1, \dots, n)$,每个个体的适应度值的计算方式如下:

$$fitness_i = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (25)$$

其中, n 为数据总量, y_i 和 \bar{y}_i 分别为真实值与预测值。

- 5)根据式(22)计算蝗虫个体的反向个体 $X_oppo_i (i=1, \dots, n)$,并计算反向种群的适应度值 $F_oppo_i (i=1, \dots, n)$ 。
- 6)选择 n 个较优的个体组成新的种群 X 。当完成种群 X 与反向种群 X_oppo 的初始化后,在这两个种群中寻找 n 个较优个体组成新的种群 X ,并将其作为要迭代更新的种群。
- 7)更新个体位置以及种群的目标位置。根据式(15)对每一个体的位置进行更新,并计算更新后种群的适应度值。新的目标位置根据更新后种群的适应度值确定。
- 8)将 IGOA 的输出结果分别赋值于 LSTM 模型的 $time_step, lr, node1, node2$,完成预测。

此时 IGOA 已完成迭代,并寻得了当前的最优位置参数,将该参数赋值给 LSTM,并将测试样本输入模型完成预测。

4 实验与分析

为了验证算法的有效性,我们进行了两部分实验,第一部分验证改进的蝗虫优化算法的有效性,第二部分验证 IGOA-LSTM 模型的有效性。

4.1 改进的蝗虫优化算法的性能分析

为了验证 IGOA 的性能,本文将 IGOA 与标准的 GOA, PSO, WOA, GA, BA 进行比较。实验中采用 8 个不同的函数进行了分析比较。

4.1.1 参数设置

为了保证实验的公平性,本文使每种算法的种群规模以及迭代次数严格保持一致,分别为 20 和 100,算法参数设置如表 1 所列。

表1 算法参数的初始化设置

Table 1 Initial values for parameters of algorithms

Algorithm	Parameter
WOA	$b: 3$
PSO	$c_1, c_2: 2.0, 2.0$
	Inertial weight; linearly decreases from 0.9 to 0.2
BA	Loudness: 0.5
	Pulse rate: 0.5 Frequency max and min: 2, 0
GA	Crossover: 1.0
	Mutation: 0.01 Selection: Roulette wheel
GOA	c : linearly decreases from 1 to 0.00001
	$k: 0.75$ $n: 1.75$
IGOA	$n: 1.75$ c : generate by chaotic mapping. The initial c is 1

选取 8 个基准函数^[11]作为比较算法性能的测试函数(见表 2)。其中, $f_1 - f_4$ 为单峰函数,在解空间中只存在一个全局最小值; $f_5 - f_8$ 为多峰函数,存在一个全局最小值与多个

局部最小值。多峰函数得到的测试结果可以反映算法在优化过程中避免局部最优解的有效性。

表2 基准函数

Table 2 Benchmark functions

Functions	Dim	Range	f_{\min}
$f_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]$	0
$f_3(x) = \sum_{i=1}^n (x_i + 0.5)^2$	30	$[-100, 100]$	0
$f_4(x) = \sum_{i=1}^n i * x_i^4 + \text{random}[0, 1]$	30	$[-1.28, 1.28]$	0
$f_5(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	$-418.9829 \times \text{Dim}$
$f_6(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
$f_7(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	30	$[-32, 32]$	0
$f_8(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600, 600]$	0

4.1.2 实验结果

表3列出了通过8个基准函数测试得出的结果。为了减小因为随机性对结果造成的影响,这里将每种算法针对每种函数都运行了30次,记录每次迭代运行得到的平均值与标准差。表3中的结果是将每种算法针对每种函数运行30次的

结果的均值,其中加粗显示的数据指每组实验中的最佳解决方案。从表中可以明显看出,相比其他优化算法以及标准GOA,IGOA在大多数情况下都可以搜索到最佳解决方案。当基准函数存在多个局部最优值时,IGOA仍然可以很好地避免局部最优,取得了最佳的效果。

表3 不同优化算法在基准函数上的实验结果

Table 3 Experimental results of different optimization algorithms on benchmark functions

	GOA		IGOA		PSO		WOA		BA		GA	
	avg	std	avg	std	avg	std	avg	std	avg	std	avg	std
f_1	7.92×10^3	8.41×10^3	6.10×10^2	2.61×10^3	1.02×10^4	1.09×10^4	1.64×10^3	7.86×10^3	3.00×10^4	1.12×10^4	2.55×10^4	1.59×10^4
f_2	9.27×10^9	1.17×10^{10}	2.41×10^3	2.40×10^4	2.04×10^{10}	1.23×10^{11}	8.56×10^9	8.55×10	8.05×10^9	6.01×10^{10}	1.99×10^{17}	2.72×10^{14}
f_3	5.84×10^3	7.24×10^3	5.83×10^2	2.47×10^3	1.36×10^4	1.34×10^4	1.75×10^3	7.88×10^3	3.05×10^4	9.83×10^3	2.49×10^4	1.57×10^4
f_4	4.38×10^{-2}	5.78×10^{-2}	3.61×10^{-2}	5.55×10^{-2}	4.92×10^{-1}	2.89×10^{-1}	4.97×10^{-1}	2.90×10^{-1}	4.97×10^{-1}	2.88×10^{-1}	4.96×10^{-1}	2.87×10^{-1}
f_5	-5.90×10^3	1.03×10^3	-4.24×10^3	9.50×10^2	-1.33×10^9	2.92×10^9	-1.18×10^4	1.37×10^3	-3.44×10^3	2.98×10^2	-6.51×10^3	2.05×10^3
f_6	1.46×10	1.95×10	1.63×10^0	7.02×10^0	3.19×10	3.46×10	4.76×10^0	2.07×10	3.12×10	2.86×10	6.63×10	4.29×10
f_7	8.41×10^0	3.32×10^0	4.46×10^0	1.82×10^0	7.11×10^6	1.11×10^7	2.43×10^0	3.94×10^0	1.68×10	1.01×10^0	1.91×10	3.69×10^{-1}
f_8	3.88×10	7.16×10	6.56×10^0	2.30×10	8.63×10	9.64×10	1.60×10	7.05×10	2.75×10^2	8.97×10	2.30×10^2	1.51×10^2

当 $p=0.5$ 时,不同算法的单位根检验(Augmented Dickey-Fuller test, ADF)结果如表4所列。当 p 值小于0.05时,可以认为算法具有显著差异;反之,则说明该优化算法取得的结果

在统计学上不显著。从表4可以看出,IGOA在每个基准函数下均表现出了较好的结果,其 p 值均小于0.05,且在基准函数 $f_1 - f_3, f_6, f_7$ 中,IGOA的表现也都优于其他几种演化算法。

表4 不同优化算法的ADF结果

Table 4 Experimental results of ADF between different optimization algorithms

	GOA	IGOA	PSO	WOA	BA	GA
f_1	4.2665×10^{-2}	8.17×10^{-10}	2.5848×10^{-2}	4.84×10^{-7}	1.1749×10^{-2}	6.110×10^{-3}
f_2	5.3890×10^{-2}	1×10^{-6}	2.0307×10^{-2}	2.6699×10^{-2}	7.2×10^{-5}	2.119×10^{-3}
f_3	7.522×10^{-3}	3.59×10^{-10}	1.26037×10^{-1}	3×10^{-6}	2.7172×10^{-2}	3.7584×10^{-2}
f_4	2.55×10^{-4}	4.95×10^{-8}	4.54×10^{-16}	1.89×10^{-15}	1.36×10^{-16}	6.32×10^{-17}
f_5	1.6067×10^{-2}	3.298×10^{-3}	9.34823×10^{-1}	2.57×10^{-4}	1.34435×10^{-1}	1.8195×10^{-2}
f_6	3.560×10^{-3}	1.43×10^{-9}	4.4150×10^{-2}	5×10^{-6}	4.13×10^{-4}	1.2342×10^{-2}
f_7	2.992×10^{-3}	1.48×10^{-9}	8.69076×10^{-1}	4.27×10^{-8}	7.4959×10^{-2}	4.20938×10^{-1}
f_8	3.1446×10^{-2}	8.80×10^{-10}	3.1172×10^{-2}	4.49×10^{-12}	1.4295×10^{-2}	8.9418×10^{-2}

4.2 IGOA-LSTM性能分析

本实验的软件环境为Window 10 64 bit,以及通过Tensorflow-gpu 2.1.0中的keras深度学习框架提供的LSTM长短记忆网络模型;硬件环境的处理器信息为Inter(R) Core(TM) i7-9700K CPU @ 3.60GHz,其RAM为16.0GB。

实验数据采用某地区2014年1月至2019年5月的真实

红细胞周统计数(包括采血量、制备量、报废量、供应量),用于预测未来一周的供应量。

4.2.1 比较算法及设置

为了验证基于改进的蝗虫优化算法的LSTM预测模型的性能,我们将其与以下模型进行对比:1)由IGOA优化的含有一层隐藏层的LSTM,命名为IGOA-LSTM1;2)由IGOA

优化的含有两层隐藏层的 LSTM,命名为 IGOA-LSTM2; 3)由标准 GOA 优化的含有一层隐藏层的 LSTM,命名为 GOA-LSTM1;4)由标准 GOA 优化的含有两层隐藏层的 LSTM,命名为 GOA-LSTM2;5)标准 LSTM 模型;6)标准 RNN 模型;7)标准 ANN 模型。

本文中,对于每个神经网络模型均采用自适应矩估计算法(adaptive moment estimation algorithm, Adam)作为训练神经网络模型的网络权重参数的优化算法。为了防止神经网络模型出现过拟合的现象,添加 dropout 正则化项并设置丢弃率为 0.1,设置神经网络的迭代次数为 50。

在 GOA 中,设置种群大小为 20,迭代次数为 50;在要优化的参数中, $time_step$ 的最小值与最大值分别为 10,20,学习率的最小值与最大值分别为 0.001,0.01,第一层隐藏层与第二层隐藏层节点数的最小值与最大值分别为 3,50;收敛因子 c 的最小值与最大值分别为 0.000 01,1。

4.2.2 损失函数

为了验证模型的预测性能,通常使用平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)作为评判标准。其中,MAE 可以避免结果受到误差的正负值的影响;MAPE 可以反映预测值与真实值之间的关系;RMSE 对误差敏感,可以很好地反映模型的预测效果。MAE, MAPE, RMSE 的计算公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (26)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \bar{y}_i}{y_i} \right| \quad (27)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (28)$$

其中, n 为数据总量大小, y_i 和 \bar{y}_i 分别为真实值和预测值。

4.2.3 模型选择

为了更好地确定作为实验参照的标准 LSTM, ANN, RNN 预测模型的实验参数,本文针对每个模型,在上述的参数范围内随机生成 100 组实验参数,分别代入每个预测模型完成预测并计算误差值,然后从这 100 组参数中选择误差值最小的一组参数作为实验模型的参数,用于构建参与实验比较的预测模型。表 5—表 7 列出了不同模型的部分实验数据。

表 5 ANN 的部分实验数据

Table 5 Partial experimental results of ANN prediction models

Structure	MAE	MAPE/%	RMSE
(0.098,37,13)	382.0407	7.87	454.1860
(0.83,21)	382.6060	7.89	454.2404
(0.064,27,23)	389.2051	8.03	462.4240
(0.047,41,21)	398.1545	8.21	472.4417

表 6 RNN 的部分实验数据

Table 6 Partial experimental results of RNN prediction models

Structure	MAE	MAPE/%	RMSE
(17,0.066,27,10)	380.1466	7.83	447.4959
(19,0.058,40)	390.6000	7.95	478.9299
(10,0.016,16)	380.2682	7.93	462.7994
(12,0.056,49)	407.6565	8.46	514.0123

表 7 LSTM 的部分实验数据

Table 7 Partial experimental results of LSTM prediction models

Structure	MAE	MAPE/%	RMSE
(13,0.081,27,44)	343.2569	7.34	439.9755
(16,0.067,41,48)	391.8676	8.29	461.9000
(14,0.082,40)	421.6977	8.84	490.4247
(11,0.052,44)	413.3168	8.57	507.4350

由于 ANN 模型不需要 $time_step$ 参数,因此要生成的 ANN 模型参数有 $(lr, node1, node2)$ 或 $(lr, node1)$, 其中 lr 为模型学习率, $node1$ 和 $node2$ 分别为第一层隐藏层、第二层隐藏层的神经元个数。如表 5 所列,最终确定 ANN(0.098,37,13)作为实验的对比模型。RNN 和 LSTM 中要生成的参数有 $(time_step, lr, node1, node2)$ 或 $(time_step, lr, node1)$, 其中 lr 为模型学习率, $node1$ 和 $node2$ 分别为第一层隐藏层、第二层隐藏层的神经元个数。如表 6、表 7 所列,最终确定 RNN(17,0.066,27,10), LSTM(13,0.081,27,44) 分别作为 RNN 和 LSTM 的实验模型代表。

4.2.4 实验结果分析

不同模型的测试结果的 MAE, MAPE, RMSE 如表 8 所列。可以看出,ANN 的预测性能相对较差,与 IGOA-LSTM2 的预测结果相比,ANN 的 MAE, MAPE, MSE 分别高出了 47.0794, 1.36%, 56.8435。而 RNN 的 MAE, MAPE, RMSE 分别要比 IGOA-LSTM2 高出 76.7175, 1.59%, 63.3395。相比标准的 LSTM 模型,GOA-LSTM 的预测误差有明显下降,而结合 IGOA 之后,其误差值比 GOA-LSTM 的要小。比较基于标准的 GOA 优化的 LSTM 模型与基于 IGOA 优化的 LSTM 模型的预测结果可知,前者的 MAE, MAPE, MSE 均高于后者。通过观察标准 GOA 优化的 LSTM 与 IGOA 优化的 LSTM 的结果数据可知,IGOA 与标准 GOA 相比,可以有效地降低 LSTM 模型的预测误差。比较 IGOA-LSTM1 与 IGOA-LSTM2 可以发现,含有两层隐藏层的 LSTM 的预测误差低于含有一层隐藏层的 LSTM。实验结果表明,IGOA 可以有效地降低 LSTM 的预测误差。

表 8 预测模型的预测结果对比

Table 8 Experimental results of partial LSTM prediction models

	MAE	MAPE/%	RMSE
GOA-LSTM1	357.9721	6.88	410.6583
GOA-LSTM2	334.9613	6.51	397.3426
IGOA-LSTM1	314.7821	6.45	384.7103
IGOA-LSTM2	303.4291	6.24	384.1564
LSTM	343.2569	7.34	439.9755
RNN	380.1466	7.83	447.4959
ANN	382.0407	7.87	454.1860

结束语 本文通过加入基于折射原理的反向学习机制与混沌机制对标准的 GOA 进行改进,并将 IGOA 与 LSTM 结合用于优化 LSTM 的参数,最后,将基于 IGOA 的 LSTM 模型用于血液库存供应量预测。与标准的 LSTM 模型、标准的 ANN 模型、标准的 RNN 模型的预测结果相比,本文提出的混合预测模型更优。实验结果表明,IGOA 的收敛速度明显快于标准的 GOA,且通过与 LSTM 相结合,提高了 LSTM 模型的预测性能。但是,通常影响红细胞供应量的不仅仅有本文提到的 3 个因素,往往还有更多的潜在因素。未来将通过

对其影响因素进行更全面的分析,来构建更准确的预测模型。

参 考 文 献

- [1] LI J, FAN J, LI M Z, et al. Discussion on the advantages of modern inventory management in blood inventory optimization management[J]. Chinese Journal of Blood Transfusion, 2019, 32(10):1038-1041.
- [2] KURUP R, ANDERSON A, BOSTON C, et al. A study on blood product usage and wastage at the public hospital, Guyana [J]. BMC Research Notes, 2016, 9(1):307-312.
- [3] ZHAO H X, YU Q, CHEN F. Application of allocation mechanism in red blood cell inventory management in blood center[J]. Journal of Clinical Hematology, 2019, 32(12):962-964.
- [4] YE M L, LI C L. Thinking on blood inventory management in blood station[J]. China Medicine and Pharmacy, 2019, 9(12):255-257.
- [5] CUI Y L, ZHAO F J, JIA J, et al. Research analysis of the system of blood supply in Hebei province[J]. Chinese Journal of Blood Transfusion, 2018, 31(4):418-423.
- [6] KHALDI R, ELAFIA A, CHIHEB R, et al. Artificial neural network based approach for blood demand forecasting; Fez transfusion blood center case study[C]//Proceedings of the 2nd International Conference on Big Data, Cloud and Applications, 2017:1-6.
- [7] FANOODI B, MALMIR B, JAHANTIGH F F. Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models[J]. Computers in Biology and Medicine, 2019, 113:103415.
- [8] FORTSCH S M, KHAPALOVA E A. Reducing uncertainty in demand for blood[J]. Operations Research for Health Care, 2016, 9:16-28.
- [9] ZHENG Y P, FAN L. A LSTM-based Forecast Method for Clinical Blood Demand[J]. Computer and Modernization, 2018, 273(5):45-48, 124.
- [10] NANDI A K, ROBERTS D J, NANDI A K. Prediction paradigm involving time series applied to total blood issues data from England[J]. Transfusion, 2020, 60(3):535-543.
- [11] BUKHARI A H, RAJA M A Z, SULAIMAN M, et al. Fractional neuro-sequential ARFIMA-LSTM for financial market forecasting[J]. IEEE Access, 2020, 8:71326-71338.
- [12] LI X, PENG L, YAO X, et al. Long short-term memory neural network for air pollutant concentration predictions; Method development and evaluation[J]. Environmental pollution, 2017, 231:997-1004.
- [13] WANG Y, LIU Y, WANG M, et al. Lstm model optimization on stock price forecasting[C]// 2018 17th International Symposium on Distributed Computing and Applications for Business Engineering and Science (dcabes). IEEE, 2018:173-177.
- [14] HOLLAND J H. Genetic algorithms [J]. Scientific American, 1992, 267(1):66-73.
- [15] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95:51-67.
- [16] KENNEDY J, EBERHART R. Particle swarm optimization [C]// Proceedings of ICNN'95-International Conference on Neural Networks. IEEE, 1995:1942-1948.
- [17] SAREMI S, MIRJALILI S, LEWIS A. Grasshopper optimization algorithm; theory and application[J]. Advances in Engineering Software, 2017, 105:30-47.
- [18] YANG X S, GANDOMI A H. Bat algorithm; a novel approach for global engineering optimization[J]. Engineering Computations, 2012, 29(5):464-483.
- [19] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [20] BARMAN M, CHOUDHURY N B D, SUTRADHAR S. A regional hybrid GOA-SVM model based on similar day approach for short-term load forecasting in Assam, India [J]. Energy, 2018, 145:710-720.
- [21] TIZHOOSH H R. Opposition-based learning; a new scheme for machine intelligence[C]// International Conference on Computational Intelligence for Modelling Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCAIAW-TIC'06). IEEE, 2005, 1:695-701.
- [22] ZHOU J, FANG W, WU X, et al. An opposition-based learning competitive particle swarm optimizer[C]//2016 IEEE Congress on Evolutionary Computation (CEC). IEEE, 2016:515-521.
- [23] LONG W, WU T, CAI S, et al. A novel grey wolf optimizer algorithm with refraction learning [J]. IEEE Access, 2019, 7:57805-57819.
- [24] ARORA S, ANAND P. Chaotic grasshopper optimization algorithm for global optimization[J]. Neural Computing and Applications, 2019, 31(8):4385-4405.
- [25] LI J, CHENG Y, CHEN K. Chaotic particle swarm optimization algorithm based on adaptive inertia weight[C]// The 26th Chinese Control and Decision Conference (2014 CCDC). IEEE, 2014:1310-1315.
- [26] SHAO P, WU Z, ZHOU X, et al. FIR digital filter design using improved particle swarm optimization based on refraction principle[J]. Soft Computing, 2017, 21(10):2631-2642.



LIU Qi, born in 1996, postgraduate. His main research interests include machine learning and data mining.



CHEN Hong-mei, born in 1971, Ph.D., professor, Ph.D supervisor, is a member of China Computer Federation. Her main research interests include granular calculation, rough sets and intelligent information processing.