

SECTION 2. Applied mathematics. Mathematical modeling.

DATA MINING FOR PARAMETER SELECTION OF SWARM INTELLIGENCE ALGORITHMS

Abstract: Swarm Intelligence algorithms commonly used to solve optimization problems. This study considers the problem of the parameters selection of the Particle Swarm Optimization algorithm. Methods of data mining are proposed to use for the selection. An example of applying regression analysis and classifying for Particle Swarm Optimization are given. The analysis carried out allows us to find good parameters of the Particle Swarm Optimization algorithm for a test optimization problem. The effectiveness of parameters found has been compared with parameters recommended by other researchers.

Key words: adaptation, data mining, particle swarm optimization, parameters selection, regression, analysis.

Language: Russian

Citation: Matrenin PV, Sekaev VG (2015) DATA MINING FOR PARAMETER SELECTION OF SWARM INTELLIGENCE ALGORITHMS. ISJ Theoretical & Applied Science 07 (27): 75-81.

Soi: <http://s-o-i.org/1.1/TAS-07-27-13> **Doi:**  <http://dx.doi.org/10.15863/TAS.2015.07.27.13>

МЕТОДЫ АНАЛИЗА ДАННЫХ ДЛЯ ПОДБОРА ПАРАМЕТРОВ АЛГОРИТМОВ РОЕВОГО ИНТЕЛЛЕКТА

Аннотация: Алгоритмы роевого интеллекта широко применяются для решения задач оптимизации. В работе рассматривается задача подбора и анализа параметров алгоритма роя частиц. Для подбора параметров предлагается использовать инструменты анализа данных, приводится пример использования регрессионного анализа и методов классификации для алгоритма роя частиц. Проведенный анализ позволил выделить эффективные наборы параметров алгоритма роя частиц для тестовой задачи. Проведено сравнение полученных параметров с рекомендованными другими авторами.

Ключевые слова: адаптация, анализ данных, алгоритм роя частиц, подбор параметров, регрессионный анализ.

Введение

Для решения многих задач оптимизации не существует точных детерминированных методов, позволяющих получить близкое к оптимальному решение задачи за приемлемое время, поэтому используются различные приближенные эвристические методы. Недостатком эвристических методов является трудность определения их параметров, которые обеспечивали бы высокую эффективность, поскольку для различных классов задач и даже для разных задач одного класса эффективные значения параметров отличаются. Целью данной работы является исследование применимости методов анализа данных, таких как регрессионный анализ и классификация, для поиска взаимосвязей между параметрами

эвристических алгоритмов и полученными решениями задач оптимизации на примере алгоритма роя частиц. На данном этапе предполагается только первоначальный анализ предложенного подхода на абстрактной тестовой задаче.

1. Методы подбора параметров эвристических алгоритмов

Задача подбора значений параметров генетического алгоритма, алгоритмов роевого интеллекта и прочих эвристических алгоритмов рассматривается во многих исследованиях. Как правило, при использовании таких методов проводятся экспериментальные подборы различных наборов параметров, затем останавливаются на параметрах, дающих в

Impact Factor:

ISRA (India) = 1.344
ISI (Dubai, UAE) = 0.829
GIF (Australia) = 0.356
JIF = 1.500

SIS (USA) = 0.912
РИИЦ (Russia) = 0.179
ESJI (KZ) = 1.042
SJIF (Morocco) = 2.031

ICV (Poland) = 6.630

среднем наилучшие результаты для рассматриваемых задач. Так, например, автор алгоритма муравьиной колонии М. Дориго указывает, что в экспериментах использовалось 3-5 вариантов значений по каждому из коэффициентов для выбора наилучших [1, с.36]. В работе [2, с.14] авторы пишут, что алгоритм колонии муравьев «сильно зависит от настроечных параметров, которые подбираются только исходя из экспериментов» (подбираются вручную) Подобные «ручные» способы подбора встречаются во многих работах по эвристическим алгоритмам, М. Педерсен называет этот способ традиционным и наиболее простым [3, с. 2].

Более сложным в реализации подходом является автоматическая настройка параметров алгоритмов с помощью различных эвристик. В обзоре эвристических методов А. П. Карпенко указывает: «...одной их особенностей популяционных алгоритмов является наличие в них значительного... числа свободных параметров. От значений этих параметров может сильно зависеть эффективность алгоритма, однако формальные рекомендации по выбору значений этих параметров, исходя из особенностей решаемой задачи, как правило, отсутствуют. В связи с этим интенсивно развиваются методы адаптации и самоадаптации значений этих параметров» [4, с.30].

Для повышения эффективности алгоритмов роевого интеллекта могут быть использованы эволюционные механизмы адаптации, например, в работах [5, с. 112] и [6, с. 3] для алгоритмов роевого интеллекта был применен генетический алгоритм, с помощью которого выполнялся подбор значений параметров. Такой способ подбора параметров принято называть мета-оптимизацией, поскольку при этом параметры эвристического алгоритма подбираются другим алгоритмом оптимизации. В работах М. Педерсена в качестве алгоритма мета-оптимизации используется простой в реализации и обладающий высокой скоростью работы алгоритм “Local Unimodal Sampling” [3, с.9].

Оба рассмотренных подхода отличаются несложными средствами выявления зависимостей между параметрами алгоритмов и их эффективностью. В первом случае просто накапливается статистика и выбирается те параметры, которые в большинстве случаев оказались более эффективными. Недостатком является принятие без обоснования положения о возможности найти значений параметров, хорошие для всех задач из некоторого обширного класса, что противоречит NFL-теореме [7]. Ведь поиск лучших параметров осуществляется уже после того, как задачи решены и получена статистика. Для других же задач эти коэффициенты могут оказаться далекими от

дающих хорошие решения. Второй подход лишен этого недостатка, поскольку подбор параметров происходит динамически именно для той задачи, которая решается в данный момент. Но и в этом случае используется только одно правило: чем лучше решение, тем эффективнее считается используемый набор параметров и тем выше вероятность, что этот набор, или набор, производный от него, будет использован в последующих итерациях.

Возможно, будет целесообразно использовать средства анализа данных для выявления закономерностей между параметрами алгоритмов роевого интеллекта и полученными решениями. Именно эта гипотеза и рассматривается в данной работе на примере алгоритма роя частиц.

2. Алгоритм роя частиц

Алгоритм роя частиц получил известность как универсальный и эффективный алгоритм решения задач оптимизации благодаря работам Кеннеди и Эберхарта [8; 3, с. 29]. Алгоритм широко освещен в литературе [3, 8, 9, 10, 11], поэтому в данной статье история возникновения алгоритма и его эвристическое обоснование опущены.

Пусть имеется задача нахождения минимума функции вида $f(\mathbf{X})$, где \mathbf{X} – вектор варьируемых переменных, которые могут принимать значения из некоторой области поиска решений \mathbf{D} размерности m , $\mathbf{D} = \{d_{min1}, d_{max1}, \dots, d_{minm}, d_{maxm}\}$. Рой представляется системой агентов (частиц), и каждая частица в каждый момент времени характеризуется значением переменных \mathbf{X} из области \mathbf{D} и значением оптимизируемой функции $f(\mathbf{X})$. Правила перемещения каждой из частиц на каждой итерации алгоритма можно записать следующим образом:

$$\begin{aligned} \mathbf{V} &\leftarrow \omega\mathbf{V} + \alpha_1(\mathbf{Pb} - \mathbf{X})\mathbf{R}_1 + \alpha_2(\mathbf{Gb} - \mathbf{X})\mathbf{R}_2 \\ v_j &\leftarrow v_{maxj}, \text{ if } v_j \geq v_{maxj}, j = 1, \dots, m \\ \mathbf{X} &\leftarrow \mathbf{X} + \mathbf{V} \\ \begin{cases} x_j \leftarrow d_{maxj}, x_j \geq d_{maxj} \\ x_j \leftarrow d_{minj}, x_j \leq d_{minj} \end{cases}, j = 1, \dots, m \end{aligned}$$

где \mathbf{X} – положение частицы,

\mathbf{V} – скорость частицы,

\mathbf{Pb} – наилучшее положение, которое занимала частица в процессе работы,

\mathbf{Gb} – наилучшее положение среди всех, найденных всеми частицами в процессе работы,

\mathbf{R}_1 и \mathbf{R}_2 – векторы случайных чисел, равномерно распределенных от 0 до 1.

Коэффициенты α_1 , α_2 , ω , и вектор \mathbf{V}_{max} – параметры PSO, которые используются в формуле и влияют на перемещения частиц в пространстве поиска. Параметры α_1 и α_2 определяют, соответственно, степень учета

Impact Factor:

ISRA (India) = 1.344	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 0.829	РИИЦ (Russia) = 0.179	
GIF (Australia) = 0.356	ESJI (KZ) = 1.042	
JIF = 1.500	SJIF (Morocco) = 2.031	

индивидуального и группового опыта агентов. Коэффициент ω характеризует инерционные свойства частиц. Вектор \mathbf{V}_{max} ограничивает скорость частиц.

В классическом PSO $\mathbf{V}_{max} = (\mathbf{D}_{max} - \mathbf{D}_{min})$, это означает, что частица за один шаг может пересечь все пространство поиска. В данной работе, как и в исследовании [6] используется дополнительный параметр β , ограничивающий скорость частиц, следующим образом [6, с.3]:

$$\mathbf{V}_{max} = \beta(\mathbf{D}_{max} - \mathbf{D}_{min}).$$

В этом случае можно записать вектор параметров PSO как $\mathbf{P} = \{\alpha_1, \alpha_2, \omega, \beta\}$.

3. Описание эксперимента

3.1. Генерация данных

Для проведения экспериментов по выявлению зависимостей между значениями параметров алгоритма роя частиц и эффективностью полученных решений необходимо иметь выборку значений параметров и полученных решений некоторой задачи оптимизации. На данном этапе исследования был решено ограничить эксперименты одной задачей, поскольку для разных задач эффективные значения параметров могут существенно отличаться согласно NFL-теореме [7] и ряду исследований, в которых показана значимость параметров алгоритма роя частиц. Различные исследования рассматривают задачи из совершенно разных областей: обучения искусственных нейронных сетей [3], календарного планирования [6], оптимизации систем электроснабжения [12] и многих других.

В данной работе была выбрана широко известная задача Розенброка [13], модифицированная для многомерного пространства решений. Тестовая задача имеет вид:

$$f(X) = \sum_{i=1}^{N-1} [(1 - x_i) + 100(x_{i+1} - x_i^2)^2] \rightarrow \min$$
$$\begin{aligned} -5 < x_i < 5, \quad i = 1, \dots, N \\ N = 10 \end{aligned} \quad (1)$$

Диапазоны значений коэффициентов определялись исходя из опыта исследований алгоритма роя частиц [3, 5, 6, 10]:

$$\begin{aligned} -3 < \alpha_1 < 3 \\ -3 < \alpha_2 < 3 \\ -1 < \omega < 1 \end{aligned} \quad (2)$$

$$0 < \beta < 1$$

Использовалось 100 частиц и 20000 итераций алгоритма. Было сгенерировано 1200 наборов случайных коэффициентов, значения которых были равномерно распределены в указанных выше диапазонах. Так как алгоритм роя частиц является стохастическим, полученные результаты зависят от случайных факторов (последовательность псевдослучайных чисел в вычислениях). Потому одного запуска алгоритма недостаточно, чтобы правильно оценить эффективность используемых коэффициентов. Для минимизации влияния случайных факторов необходимо выполнить процедуру многократного запуска и выбора лучшего решения несколько раз и затем взять средний результат, который и покажет эффективность решения задачи на некотором наборе параметров. В данном эксперименте для каждого набора параметров тестовая задача решалась 10 раз, затем определялось среднее значение критерия $f(\mathbf{X})$ (1).

В итоге было сформировано 1200 кортежей вида $\langle \mathbf{P}, \varphi \rangle = \langle \alpha_1, \alpha_2, \omega, \beta, \varphi \rangle$, где φ является полученным после усреднения показателем качества соответствующего набора параметров.

3.2. Регрессионный анализ

Для построения зависимости значения критерия задачи (1) φ от параметров алгоритма роя частиц \mathbf{P} было построено полиномиальное уравнение регрессии 4 степени следующего вида:

$$\varphi^*(\mathbf{P}) = \sum_{i=1}^4 \sum_{j=1}^4 k_{ij}(p_i)^j + C \quad (3)$$

где $\varphi^*(\mathbf{P})$ – оценка показателя качества φ при использовании вектора параметров \mathbf{P} ,

p_i – параметр алгоритма роя частиц ($i = 1, 2, 3, 4$ для $\alpha_1, \alpha_2, \omega, v_{max}$, соответственно),

k_{ij} – коэффициент полинома при параметре p_i в степени j (табл.1),

C – свободный член полинома, раный в данном случае 18449.5.

Степень полинома выбрана равной 4, так как при более низких степенях ошибка регрессии была на порядок больше, а повышение степени не привело к существенным улучшениям точности модели. Для нахождения коэффициентов полинома t свободного члена была использована среда разработки систем интеллектуального анализа данных «KNIME» (www.knime.org).

Impact Factor:

ISRA (India) = 1.344	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 0.829	РИИЦ (Russia) = 0.179	
GIF (Australia) = 0.356	ESJI (KZ) = 1.042	
JIF = 1.500	SJIF (Morocco) = 2.031	

Таблица 1

Коэффициенты уравнения регрессии.

P	$j = 1$	$j = 2$	$j = 3$	$j = 4$
α_1	-1366.9	-1061.8	2.55	80.37
α_2	-8021.9	438.0	693.3	-8.76
ω	-10.57	-3938.9	-770.6	5394.5
β	-25913.7	82258.0	-104806	47376.6

Используя уравнение (3) можно найти глобальный экстремум оценки $\varphi^*(P)$ в области значений параметров (2). Но построенное уравнение регрессии является недостаточно точным в предсказании показателя качества φ . Отклонение оценочных значений $\varphi^*(P)$ от

истинных значений φ проиллюстрированы рисунком 1, где линией показана зависимость значения $\varphi^*(P)$ от α_2 , а маркеры показывают значения φ при данных значениях параметра α_2 в сгенерированном наборе коротежей.




Рисунок 1– Регрессионная кривая для параметра α_2 .

3.3. Построение классификатора

Помимо регрессионного анализа был проведено исследование параметров с помощью классификаторов. Среди всех коротежей было выбрано 5% наилучших по значению критерия φ , которые поместили в класс «А». Все остальные коротежи поместили в класс «В». Была выдвинута гипотеза, что можно построить классификатор, способный по обучающей выборке создать правила, отличающие коротежи класса «А» от коротежей класса «В» по набору параметров. В

случае подтверждения гипотезы можно применить полученные правила для более точного выбора наиболее эффективных для решаемой задачи параметров.

В обучающей выборке использовалось 75% коротежей класса 1 и 10% коротежей класса «В». Таким образом, совокупности тестовая выборка составила 12.75%. Были применены классификаторы из широко распространенной Open Source библиотеки «Weka», версии 3.7 (которая легко интегрируется с упомянутой выше

Impact Factor:

ISRA (India) = 1.344	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 0.829	РИИЦ (Russia) = 0.179	
GIF (Australia) = 0.356	ESJI (KZ) = 1.042	
JIF = 1.500	SJIF (Morocco) = 2.031	

средой «KNIME»). В таблице 2 приведены полученные на тестовой выборке результаты применения различных классификаторов.

Из таблицы 2 видно, что классификатор JRip позволил построить наиболее точную среди прочих классификаторов модель,

предсказывающую, попадут ли результаты решения тестовой задачи оптимизации при заданных параметрах в число 5% наиболее эффективных среди случайно сгенерированных наборов параметров.

Таблица 2

Ошибки классификации кортежей.

Классификатор	Ошибка (%)
JRip	9.7
MulilayerPerceptron	9.8
RandomForest	10.3
LMT	11.6
LibSVM	11.8
NaiveBayes	12.3
J48	15.7
PART	17.0

Помимо относительно высокой точности, модель классификатора JRip очень проста и состоит всего из одного правила или конъюнкта (в общем случае JRip строит модель в дизъюнктивной нормальной форме):

$if(\alpha_2 > 1.4192 \ \& \ \alpha_1 > -1.10315 \ \& \ \alpha_1 < 1.92441)$
 $then \ class = A$
 $else \ class = B$

Полученная модель показывает, что эффективные решения с высокой вероятностью можно получить, используя значение параметра α_2 выше 1.4192 и α_1 в диапазоне от -1.10315 до 1.92441.

Следующим шагом является объединение моделей, полученных с помощью классификации и с помощью Регрессионного анализа. Для этого модель, построенная классификатором JRip используется как набор ограничений при поиске экстремума регрессионной зависимости. В итоге совмещение результатов регрессионного анализа и классификатора дает следующие параметры алгоритма роя частиц для тестовой задачи:

$$\begin{aligned} \alpha_1 &= 1.92441 \\ \alpha_2 &= 1.4192 \\ \omega &= 0.661 \\ \beta &= 0.291 \end{aligned} \quad (4)$$

3.3. Сравнение с рекомендуемыми параметрами других авторов

Для оценки эффективности полученных параметров (4) было выполнено 200 запусков решения тестовой задачи (1) алгоритмом роя частиц с данными значениями параметров. Затем

были определены параметры алгоритм роя частиц, рекомендуемые другими исследователями как эффективные. Известные исследователи в области роевого интеллекта Эберхарт и Ши приводятся следующие значения параметров, эффективные для многих задач непрерывной оптимизации [3, с.19; 11]:

$$\begin{aligned} \alpha_1 &= 1.49445 \\ \alpha_2 &= 1.49445 \\ \omega &= 0.729 \\ \beta &= 1.0 \end{aligned} \quad (5)$$

при этом β не рассматривается как изменяемый параметр, поскольку в классическом алгоритме роя частиц максимальные значения скоростей частиц ограничены только размерами пространства поиска решений.

В работе М. Педерсена [10, с. 7] приводятся несколько наборов параметров для различных количеств итераций и различных размерностей задач оптимизации. Для рассматриваемой ситуации (размерность задачи равна 10, а число итераций алгоритма – 20000) рекомендуется использовать параметры

$$\begin{aligned} \alpha_1 &= -0.2746 \\ \alpha_2 &= 4.8976 \\ \omega &= -0.3488 \\ \beta &= 1.0 \end{aligned} \quad (6)$$

в этой работе ограничения на скорости частиц так же не рассматриваются как изменяемый параметр алгоритма.

Impact Factor:

ISRA (India) = 1.344	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 0.829	ПИИЦ (Russia) = 0.179	
GIF (Australia) = 0.356	ESJI (KZ) = 1.042	
JIF = 1.500	SJIF (Morocco) = 2.031	

Как указано выше, для всех трех наборов параметров тестовая задача (1) была решена по 200 раз. Результаты, полученные при

использовании этих наборов, приведены в таблице 3.

Таблица 3

Сравнение наборов параметров.

Набор параметров	Среднее значение критерия	Минимальное значение критерия
(3)	0.59	8.63E-9
(4)	8.87	2.90E-11
(5)	879.24	588.92

Таким образом, использование регрессионного анализа и классификатора в среднем дало результаты решения тестовой задачи намного лучше результатов при выборе рекомендуемых в литературе значений. С одной стороны, этого следовало ожидать, поскольку значения параметров (4) и (5) были подобраны для широкого класса задач, а параметры (4) для одной конкретной задачи (1). С другой стороны, большинство возникающих на практике задачи оптимизации являются нестандартными, поэтому использование рекомендованных фиксированных значений параметров может не привести к получению высокоэффективных решений для большинства случаев. При этом следует отметить, что результаты с параметрами (4) можно назвать очень хорошими по сравнению со средним результатом решений, полученных на этапе генерации данных, то есть с произвольными значениями параметров. Среди 1200 кортежей, полученных на этом этапе, среднее значение критерия составляет 955.4, при этом худшие результаты превышали 3000.

Заключение

Для нахождения эффективных значений параметров алгоритма роя частиц были построены модели на основании регрессионного анализа и на основании классификации методом JRip. Модели строились по обучающим данным, содержащим различные значения параметров и полученные с этими значениями усредненные результаты решения тестовой задачи. Регрессионный анализ позволил создать модель зависимости между значениями параметров алгоритма и эффективностью полученных с ними решений. Классификатор JRip позволил выделить области наиболее эффективных значений параметров. Полученные области были

использованы как области допустимых значений при поиске экстремумов регрессионных кривых по каждому из параметров.

Найденные таким образом параметры показали качество решений на порядки выше среднего по выборке (средний результат 0.59 против 955.4). Таким образом гипотеза о возможности найти эффективные значения параметров алгоритма роя частиц для отдельной тестовой задачи была подтверждена.

Так же было проведено сравнение со значениями параметров, рекомендованными в литературе, сравнение показало значительное превосходство найденных параметров (0.59 против 8.87 и 879.24). При этом нужно отметить, что рекомендованные параметры относились к широкому классу задач, и параметры, рекомендованные Дж. Кеннеди и Р. Эберхартом (5), показали очень высокую эффективность.

Направление дальнейшие работы

Дальнейшим этапом исследования является исследование применимости подхода для решения различных задач из некоторого ограниченного класса. Другими словами, необходимо проверить, будут ли параметры, подобранные на одной задаче эффективными на других подобных задачах, поскольку главным недостатком описанного подхода является необходимость многократного решения тестовых задач на сгенерированных наборах параметров. Но если единожды подобранные параметры по одной задаче окажутся эффективными на всех аналогичных задачах, то такой подход позволит значительно снизить время решения задач, в отличие от методов мета-оптимизации и ручного подбора параметров, которые предполагают выполнение подбора для каждой решаемой задачи отдельно.

Impact Factor:

ISRA (India) = 1.344	SIS (USA) = 0.912	ICV (Poland) = 6.630
ISI (Dubai, UAE) = 0.829	PIHHI (Russia) = 0.179	
GIF (Australia) = 0.356	ESJI (KZ) = 1.042	
JIF = 1.500	SJIF (Morocco) = 2.031	

References:

1. Dorigo M, Maniezzo V, Colorni A (1996) The Ant System: Optimization by a colony of cooperating agents. IEEE Transactions on Systems, Man, and Cybernetics Part B. V. 26. No. 1. pp. 29-41.
2. Churakov M, Yakushev A (2006) Muravinnye algoritmy. Available: <http://rain.ifmo.ru/cat/data/theory/unsorted/ant-algo-2006/article.pdf> (Accessed: 10.07.2015).
3. Pedersen M, Chipper A (2010) Simplifying Particle Swarm Optimization. Applied Soft Computing. Vol. 10, Iss. 2, pp. 618-628.
4. Karpenko AP (2012) Populyatsionnye algoritmy global'noi optimizatsii. Obzor novykh i maloizvestnykh algoritmov. Prilozhenie k zhurnalu «Informatsionnye tekhnologii». No 7, pp. 1-32.
5. Matrenin PV (2013) Pazrabotka i issledovanie adaptivnykh metodov roevogo intellekt v zadachah kalendarnogo planizovaniya. Avtomatika i programmaya inzheneriya. No, 1(13), pp. 109-114.
6. Matrenin PV, Sekaev VG (2015) Particle Swarm optimization with velocity restriction and evolutionary parameters selection for scheduling problem. Control and Communications (SIBCON), International Siberian Conference on, pp. 1-5.
7. Wolpert DH, Macready WG (1997) No Free Lunch Theorems for Optimization. IEEE Transactions on Evolutionary Computation. No. 1(1), pp. 67-82.
8. Kennedy J, Eberhart R (1995) Particle Swarm Optimization. IEEE International Conference on Neural Network, Piscataway. pp. 1942-1948.
9. Matrenin PV, Sekaev VG (2013) Sistemnoe opisaniye algoritmov roevogo intellekta. Programmaya inzheneriya. No. 12, pp. 39-45.
10. Pedersen M (2010) Good Parameters for Particle Swarm Optimization. Hvass Laboratories Technical Report No. HL1001.
11. Eberhart RC, Shi Y (2001) Particle swarm optimization: developments, applications and resources. Proceeding of the Congress on Evolutionary Computation. Vol. 1, pp. 81-86.
12. Manusov V, Tretyakova E, Matrenin P (2015) Population-based algorithms for optimization of the reactive power distribution and selection of the cable cross-section in the power supply systems. Applied Mechanics and Materials. Vol. 792, pp. 230-236.
13. Rosenbrock HH (1960) An automatic method for finding the greatest or least value of a function. The Computer Journal. T. 3, pp.175-184.