

机器学习PAI

PAI实战文章合集

PAI实战文章合集

PAI平台深度学习Caffe框架实现图像分类的模型训练

背景


我们在之前的文章中介绍过如何通过PAI内置的TensorFlow框架实验基于Cifar10的图像分类，文章链接：<https://yq.aliyun.com/articles/72841>。

本文将介绍另一个深度学习框架Caffe，通过Caffe只需要填写一些配置文件就可以实现图像分类的模型训练。

关于PAI的深度学习功能开通，请务必提前阅读https://help.aliyun.com/document_detail/49571.html文末提供了相关下载链接。

数据介绍

本文使用的数据是开源数据集cifar10，这份数据是一份对包含6万张像素为32*32的彩色图片，这6万张图片被分成10个类别，分别是飞机、汽车、鸟、毛、鹿、狗、青蛙、马、船、卡车。数据集截图：



目前这份数据已经内置在PAI提供的公共数据集中，以jpg格式存储。任何PAI的用户都可以在深度学习组件的数据源OSS路径中直接输入，


- 测试数据：oss://dl-images.oss-cn-shanghai-internal.aliyuncs.com/cifar10/caffe/images/cifar10_test_image_list.txt
- 训练数据：oss://dl-images.oss-cn-shanghai-internal.aliyuncs.com/cifar10/caffe/images/cifar10_train_image_list.txt

如图：



格式转换

目前PAI上的Caffe框架只支持特定的格式，所以需要首先将jpg格式的图片进行格式转换。



经过格式转换，可以在自己的OSS路径下生成如下文件，训练数据和测试数据各一份。

☐	data_file_list.txt	5.85KB	标准存储	2017-06-05 19:33:52
☐	data_mean.binaryproto	768.014KB	标准存储	2017-06-05 19:33:52

需要记录对应的OSS路径用于net文件的填写，假设路径名分别是：

训练数据data_file_list.txt：bucket/cifar/train/data_file_list.txt

训练数据data_mean.binaryproto:bucket/cifar/train/data_mean.binaryproto

测试数据data_file_list.txt：bucket/cifar/test/data_file_list.txt

测试数据data_mean.binaryproto:bucket/cifar/test/data_mean.binaryproto

Caffe配置文件

Net文件编写，对应上文格式转换生成的路径：

```

    }
    transform_param {
      mean_file: "bucket/cifar/train/data_mean.binaryproto"
      crop_size: 31
    }
    binary_data_param {
      source: "bucket/cifar/train/data_file_list.txt"
      batch_size: 100
    }
  }
  layer {
    name: "cifar"
    type: "BinaryData"
    top: "data"
    top: "label"
    include {
      phase: TEST
    }
    transform_param {
      mean_file: "bucket/cifar/test/data_mean.binaryproto"
      crop_size: 31
    }
    binary_data_param {
      source: "bucket/cifar/test/data_file_list.txt"
      batch_size: 100
    }
  }
}

```

Solver文件编写：

```

# The train/test net protocol buffer definition
net: "填写net文件的OSS路径"
# test_iter specifies how many forward passes the test should carry out.
# In the case of MNIST, we have test batch size 100 and 100 test iterations,
# covering the full 10,000 testing images.
test_iter: 100
# Carry out testing every 500 training iterations.
test_interval: 500
# The base learning rate, momentum and the weight decay of the network.
base_lr: 0.001
momentum: 0.9
weight_decay: 0.004
# The learning rate policy
lr_policy: "fixed"
# Display every 100 iterations
display: 100
# The maximum number of iterations
max_iter: 5000
# snapshot intermediate results
snapshot_after_train: true
# snapshot: 10000
# snapshot_format: HDF5
snapshot_prefix: "生成model的存储路径"
# solver mode: CPU or GPU
solver_mode: GPU
data_distribute_mode: MANUALLY
model_average_iter_interval: 1

```

运行

将编辑好的Solver文件和Net文件全部传到OSS上，拖动caffe训练组件如图，在Solver文件路径上选择OSS上提交的Solver文件，运行即可。



生成的图片分类model文件可以在OSS对应路径下查看，可以用以下模型进行图片分类

☐ [cifar10_iter_5000.caffemodel](#)

☐ [cifar10_iter_5000.solverstate](#)


日志查看可以参照本文开头提供的“Tensorflow实现图像分类”。

（本文数据为虚构，仅供实验）

一、背景

本文将针对阿里云平台上图算法模块来进行实验。图算法一般被用来解决关系网状的业务场景。与常规的结构化数据不同，图算法需要把数据整理成首尾相连的关系图谱。图算法更多的是考虑边和点的概念。阿里云机器学习平台上提供了丰富的图算法组件，包括K-Core、最大联通子图、标签传播聚类等。本文的业务场景如下：

下图是已知的一份人物通联关系图，每两个人之间的连线表示两人有一定关系，可以是同事关系或者亲人关系等。已知“Enoch”是信用用户，“Evan”是欺诈用户，计算出其它人的信用指数。通过图算法，可以算出图中每个人是欺诈用户的概率，这个数据可以方便相关机构做风控。



二、数据集介绍


数据源：本文数据为自己生成，用于实验。具体字段如下：

字段名	含义	类型	描述
start_point	边的起始节点	string	人
end_point	边结束节点	string	人
count	关系紧密度	double	数值越大，两人的关系越紧密

数据截图：

start_point ▲	end_point ▲	count ▲
Enoch	Evan	10
Enoch	Gregary	2
Gregary	Hale	6
Evan	Hugo	2
Evan	Jeff	4
Gregary	Keith	7
Jeff	Keith	5
Hale	Jeff	11
Keith	Leif	3
Keith	Lionel	1
Leif	Mick	4


三、数据探索流程



首先，实验流程图：

1.最大联通子图

最大联通子图的功能很好理解，前面已经介绍了，图算法的输入数据是关系图谱结构的。最大联通子图可以找到有通联关系的最大集合，在团伙发现的场景中可以排除掉一些与风控场景无关的人。本次实验通过“最大联通子图”组件将数据中的群体分为两部分，并赋予group_id。通过“SQL脚本”组件和“JOIN”组件去除下图



中的无关联人员。

2.单源最短路径

通过“单源最短路径”组件探查出每个人的一度人脉、二度人脉关系等。distance讲的是“Enoch”通过几个人可以联络到目标人。如下图：

start_node ▲	dest_node ▲	distance ▲	distance_cnt ▲
Enoch	Hale	2	1
Enoch	Leif	3	1
Enoch	Hugo	2	1
Enoch	Keith	2	1
Enoch	Jeff	2	1
Enoch	Evan	1	1
Enoch	Lionel	3	1
Enoch	Mick	4	1
Enoch	Gregary	1	1
Enoch	Noah	4	1
Enoch	Enoch	0	0

3.标签传播分类

“标签传播分类”算法为半监督的分类算法，原理是用已标记节点的标签信息去预测未标记节点的标签信息。在算法执行过程中，每个节点的标签按相似度传播给相邻节点。

调用“标签传播分类”组件除了要有所有人员的通联图数据以外，还要有人员打标数据。这里通过“已知数据-读odps”组件导入打标数据(weight表示目标是欺诈用户的概率)：

point ▲	point_type ▲	weight ▲
Enoch	信用用户	1
Evan	欺诈用户	0.8

通过SQL对结果进行筛选，最终结果展现的是每个人涉嫌欺诈的概率，数值越大表示是欺诈用户的概率越大。

node ▲	tag ▲	weight ▼
Hugo	欺诈用户	1
Evan	欺诈用户	0.8
Noah	欺诈用户	0.42059743476528927
Jeff	欺诈用户	0.34784053907648443
Mick	欺诈用户	0.3113287445872401
Lionel	欺诈用户	0.2938277295951075
Leif	欺诈用户	0.24091136964145973
Keith	欺诈用户	0.2264783897173419

四、其它

参与讨论：云栖社区公众号

免费体验：阿里云数加机器学习平台

（本文数据为虚构，仅供实验）

一、背景

很多农民因为缺乏资金，在每年耕种前会向相关机构申请贷款来购买种地需要的物资，等丰收之后偿还。农业贷款发放问题是一个典型的数据挖掘问题。贷款发放人通过往年的数据，包括贷款人的年收入、种植的作物种类、历史借贷信息等特征来构建经验模型，通过这个模型来预测受贷人的还款能力。本文借助真实的农业贷款业务场景，利用回归算法解决贷款发放业务。线性回归，是利用数理统计中回归分析，来确定两种或两种以上变量间相互依赖的定量关系的一种统计分析方法，运用十分广泛。本文通过农业贷款的历史发放情况，预测是否给预测集的用户发放他们需要的金额的贷款。

二、数据集介绍

具体字段如下：

字段名	含义	类型	描述
id	数据唯一标识符	string	人


name	用户名	string	人
region	用户所属地区	string	从北到南排列
farmsize	拥有土地大小	double	土地面积
rainfall	降雨量	double	降雨量
landquality	土地质量	double	土地质量数值越大越好
farmincome	收入	double	年收入
maincrop	种植作物	string	种植作物的种类
claimtype	贷款类型	string	两种
claimvalue	贷款金额	double	贷款金额

数据截图：

id ▲	name ▲	region ▲	farmsize ▲	rainfall ▲	landquality ▲	farmincome ▲	maincrop ▲	claimtype ▲	claimvalue ▲
"id..."	"name..."	"midland..."	1480	30	8	330729	"wheat"	"decommiss..."	74703.1
"id..."	"name..."	"north"	1780	42	9	734118	"maize"	"arable_dev"	245354
"id..."	"name..."	"midland..."	500	69	7	231965	"rapeseed"	"decommiss..."	84213
"id..."	"name..."	"southw..."	1860	103	3	625251	"potatoes"	"decommiss..."	281082
"id..."	"name..."	"north"	1700	46	8	621148	"wheat"	"decommiss..."	122006
"id..."	"name..."	"southea..."	1580	42	7	445785	"maize"	"arable_dev"	122135
"id..."	"name..."	"southea..."	1820	29	6	211605	"maize"	"arable_dev"	68969.2
"id..."	"name..."	"southea..."	1640	108	7	1167040	"maize"	"arable_dev"	485011
"id..."	"name..."	"southw..."	1600	101	5	756755	"wheat"	"decommiss..."	160904
"id..."	"name..."	"southea..."	600	80	6	267928	"wheat"	"arable_dev"	90350.6

三、数据探索流程

首先，实验流程图：




1.数据源

数据的输入有两部分，贷款训练集用来进行回归模型的训练，共二百条数据，是历史贷款数据，包括一些 farmsize、rainfall等特征，claimvalue是贷款收回的金额。贷款预测集是今年申请贷款者，claimvalue是农民申请的贷款金额，共71人。我们通过已有的二百多条历史数据，预测给七十一人中的哪些申请贷款人发放贷款。

2.特征工程

将一些字符串类型的数据，根据他们的含义映射成数字。比如说region字段，我们将其中的north、middle、south按照从北到南的顺序分别映射成0、1、2。然后通过类型转换将字段转换成double类型，这样就可以进行下面的回归计算了。

如下图：



3.回归及预测

线性回归组件对于历史数据训练并生成回归模型，在预测组件中利用回归模型对于预测集数据进行了预测。通过合并列组件将用户ID、预测值、申请的贷款值合并。预测值表示的是用户的还贷能力（预期可以归还的金额）。

claimvalue ▲	prediction_score ▲	id ▲
172753	164424.3413395547	1
93415.4	146370.52166158534	2
46800.2	41879.999271195346	3
131728	192648.19077439874	4
89040.8	76369.8134277192	5
135493	103695.67105783387	6
88906.8	136845.30246967232	7
147159	144156.81362150217	8
277397	466728.8170899566	9
67547.3	131340.40980772747	10
345394	402192.7992950041	11


4.回归模型评估

通过回归模型评估组件对于回归模型进行评估。

字段名称	描述
SST	总平方和
SSE	误差平方和
SSR	回归平方和
R2	判定系数
R	多重相关系数
MSE	均方误差
RMSE	均方根误差
MAE	平均绝对误差
MAD	平均误差
MAPE	平均绝对百分误差
count	行数
yMean	原始因变量的均值
predictionMean	预测结果的均值

5.发放贷款人

通过过滤与映射组件筛选出可以获得贷款的人，这里的业务逻辑是针对每个客户，如果他被预测得到的还款能力大于他申请贷款的金额，就对他发放贷款。



四、其它

参与讨论：云栖社区公众号

免费体验：阿里云数加机器学习平台

往期文章：

【玩转数据系列一】人口普查统计案例

【玩转数据系列二】机器学习应用没那么难，这次教你玩心脏病预测

【玩转数据系列三】利用图算法实现金融行业风控

【玩转数据系列四】听说啤酒和尿布很配？本期教你用协同过滤做推荐

机器学习算法基于信用卡消费记录做信用评分

背景

如果你是做互联网金融的，那么一定听说过评分卡。评分卡是信用风险评估领域常用的建模方法，评分卡并不简单对应于某一种机器学习算法，而是一种通用的建模框架，将原始数据通过分箱后进行特征工程变换，继而应用于线性模型进行建模的一种方法。

评分卡建模理论常被用于各种信用评估领域，比如信用卡风险评估、贷款发放等业务。另外，在其它领域评分卡常被用来作为分数评估，比如常见的客服质量打分、芝麻信用分打分等等。在本文中，我们将通过一个案例为大家讲解如何通过PAI平台的金融板块组件，搭建出一套评分卡建模方案。

本实验案例可在机器学习PAI平台使用，包含整个实验流程和数据：



数据集介绍


源表字段信息			
字段	类型	前 100 条记录	
id	STRING	1,2,3,4,5	
limit_bal	BIGINT	20000,50000,	
sex	STRING	女,男	
education	STRING	本科	
marriage	STRING	已婚,未婚	
age	BIGINT	24,26,34,37,5	
pay_0	BIGINT	-1,0,2	
pay_2	BIGINT	0,2	
pay_3	BIGINT	-1,0	
pay_4	BIGINT	-1,0	
pay_5	BIGINT	-2,0	
pay_6	BIGINT	-2,0,2	
bill_amt1	DOUBLE	2682.0,3913.0,	
bill_amt2	DOUBLE	1725.0,3102.0,	
bill_amt3	DOUBLE	689.0,2682.0,	
bill_amt4	DOUBLE	0.0,3272.0,14	
bill_amt5	DOUBLE	0.0,3455.0,14	
bill_amt6	DOUBLE	0.0,3261.0,15	
pay_amt1	DOUBLE	0.0,1518.0,20	
pay_amt2	DOUBLE	689.0,1000.0,	
pay_amt3	DOUBLE	0.0,1000.0,12	
pay_amt4	DOUBLE	0.0,1000.0,11	
pay_amt5	DOUBLE	0.0,689.0,100	
pay_amt6	DOUBLE	0.0,679.0,100	

这是一份国外某机构开源的数据集，数据的内容包括每个用户的一些性别、教育、婚姻、年龄等属性，同时也包含用户过去一段时间的信用卡消费情况和账单情况。payment_next_month是目标队列，表示用户是否偿还信用卡账单，1表示偿还，0表示没有偿还。

数据供30000条。数据集下载地址：<https://www.kaggle.com/uciml/default-of-credit-card-clients-dataset>

实验流程

先来看下实验图：



现在对一些关键节点进行介绍：

(1) 拆分

将输入数据集分为两部分，一部分用来训练模型，另一部分用来预测评估。

(2) 分箱

分箱组件类似于onehot编码，可以将数据按照分布映射成更高维度的特征。我们以age这个字段为例，分箱组件可以按照数据在不同区间的分布进行分箱操作，分箱结果如图：

	Index ▲	Label ▲	Constraint		WoE		Number			Rate		
			Operator	Value	WoE ▲	Chart	Total ▲	Positive ▲	Negative ▲	Total ▲	Positive ▲	Negative
	0	(-inf,25]	▼		0.249		3082	822	2260	12.84%	15.5%	12.09%
	1	[25,27]	▼		-0.12		2184	439	1745	9.1%	8.28%	9.33%
	2	[27,29]	▼		-0.137		2421	480	1941	10.09%	9.05%	10.38%
	3	[29,31]	▼		-0.196		2084	394	1690	8.68%	7.43%	9.04%
	4	[31,34]	▼		-0.2		2791	526	2265	11.63%	9.92%	12.11%
	5	[34,37]	▼		-0.016		2622	572	2050	10.93%	10.79%	10.96%
	6	[37,40]	▼		-0.025		2224	482	1742	9.27%	9.09%	9.32%
	7	[40,43]	▼		0.026		1823	411	1412	7.6%	7.75%	7.55%
	8	[43,49]	▼		0.083		2628	619	2009	10.95%	11.67%	10.74%
	9	(49,+inf)	▼		0.215		2141	557	1584	8.92%	10.51%	8.47%
	-2	ELSE	▼				-	-	-	-	-	-

最终分箱组件的输出如图

，每个字段都被分箱到多个区间上：

序号 ▲	feature ▲	json ▲
1	limit_bal	{ "bin": {"norm": [{"iv": 0.076602, "n": 2104, "p": 1187, "prate": 0.360681, "total": 3291, "value": "(-inf,30000]", "woe": 0.687921}, {"iv": 0.009549999999999999, "n": 2095...
2	age	{ "bin": {"norm": [{"iv": 0.008506, "n": 2260, "p": 822, "prate": 0.26671, "total": 3082, "value": "(-inf,25]", "woe": 0.248953}, {"iv": 0.00126, "n": 1745, "p": 439, "prate": 0.2...
3	pay_0	{ "bin": {"norm": [{"iv": 0.047172, "n": 5735, "p": 1052, "prate": 0.155002, "total": 6787, "value": "(-inf,-1]", "woe": -0.435562}, {"iv": 0.170225, "n": 10252, "p": 1518, "prat...
4	pay_2	{ "bin": {"norm": [{"iv": 0.007479, "n": 2483, "p": 547, "prate": 0.180528, "total": 3030, "value": "(-inf,-2]", "woe": -0.252442}, {"iv": 0.028735, "n": 4094, "p": 779, "prate": ...
5	pay_3	{ "bin": {"norm": [{"iv": 0.006939, "n": 2676, "p": 601, "prate": 0.183399, "total": 3277, "value": "(-inf,-2]", "woe": -0.233151}, {"iv": 0.032692, "n": 4040, "p": 744, "prate": ...
6	pay_4	{ "bin": {"norm": [{"iv": 0.004796, "n": 2826, "p": 665, "prate": 0.19049, "total": 3491, "value": "(-inf,-2]", "woe": -0.186498}, {"iv": 0.02676, "n": 3658, "p": 736, "prate": 0.1...
7	pay_5	{ "bin": {"norm": [{"iv": 0.003088, "n": 2925, "p": 717, "prate": 0.19687, "total": 3642, "value": "(-inf,-2]", "woe": -0.145641}, {"iv": 0.023437, "n": 3740, "p": 729, "prate": 0....
8	pay_6	{ "bin": {"norm": [{"iv": 0.002296, "n": 3135, "p": 788, "prate": 0.200867, "total": 3923, "value": "(-inf,-2]", "woe": -0.120564}, {"iv": 0.019253, "n": 3847, "p": 783, "prate": ...
9	bill_amt1	{ "bin": {"norm": [{"iv": 0.001611, "n": 1818, "p": 584, "prate": 0.243131, "total": 2402, "value": "(-inf,282]", "woe": 0.124741}, {"iv": 3e-05, "n": 1866, "p": 532, "prate": 0.2...
10	bill_amt2	{ "bin": {"norm": [{"iv": 0.000701, "n": 1929, "p": 593, "prate": 0.235131, "total": 2522, "value": "(-inf,0]", "woe": 0.08076999999999999}, {"iv": 0, "n": 1789, "p": 508, "prat...
11	bill_amt3	{ "bin": {"norm": [{"iv": 0.000503, "n": 2158, "p": 653, "prate": 0.232302, "total": 2811, "value": "(-inf,0]", "woe": 0.064972}, {"iv": 5.2e-05, "n": 1541, "p": 448, "prate": 0.2...
12	bill_amt4	{ "bin": {"norm": [{"iv": 0.000712, "n": 2362, "p": 721, "prate": 0.233863, "total": 3083, "value": "(-inf,0]", "woe": 0.073708}, {"iv": 0.000344, "n": 1317, "p": 400, "prate": 0....
13	bill_amt5	{ "bin": {"norm": [{"iv": 0.001599, "n": 2535, "p": 799, "prate": 0.239652, "total": 3334, "value": "(-inf,0]", "woe": 0.105744}, {"iv": 2.4e-05, "n": 1141, "p": 330, "prate": 0.2...
14	bill_amt6	{ "bin": {"norm": [{"iv": 0.0002, "n": 2917, "p": 857, "prate": 0.22708, "total": 3774, "value": "(-inf,0]", "woe": 0.035459}, {"iv": 0.000112, "n": 791, "p": 236, "prate": 0.2297...
15	pay_amt1	{ "bin": {"norm": [{"iv": 0.098387, "n": 2681, "p": 1516, "prate": 0.36121, "total": 4197, "value": "(-inf,0]", "woe": 0.690218}, {"iv": 0.000189, "n": 483, "p": 143, "prate": 0.2...
16	pay_amt2	{ "bin": {"norm": [{"iv": 0.068019, "n": 2864, "p": 1441, "prate": 0.334727, "total": 4305, "value": "(-inf,0]", "woe": 0.573451}, {"iv": 0.002296, "n": 356, "p": 139, "prate": 0....
17	pay_amt3	{ "bin": {"norm": [{"iv": 0.061212, "n": 3232, "p": 1541, "prate": 0.322858, "total": 4773, "value": "(-inf,0]", "woe": 0.519663}, {"iv": 7.7e-05, "n": 31, "p": 7, "prate": 0.1842...

（3）样本稳定指数PSI

样本稳定指数是衡量样本变化所产生的偏移量的一种重要指标，通常用来衡量样本的稳定程度，比如样本在两个月份之间的变化是否稳定。通常变量的PSI值在0.1以下表示变化不太显著，在0.1到0.25之间表示有比较显著的变化，大于0.25表示变量变化比较剧烈，需要特殊关注。

本案例中，可以综合比较拆分前后以及分箱结果的样本稳定程度，返回每个特征的PSI数值：

收起

展开

Feature ▲	Bin ▲	Test % ▲	Base % ▲	Test - Base ▲	ln(Test/Base) ▲	PSI ▲
☐ limit_bal	-	-	-	-	-	0.0019
☒ age	-	-	-	-	-	0.0005
☐ pay_0	-	-	-	-	-	0.0002
☐ pay_2	-	-	-	-	-	0.0006
☐ pay_3	-	-	-	-	-	0.0005
☐ pay_4	-	-	-	-	-	0.0016
☐ pay_5	-	-	-	-	-	0.0015
☐ pay_6	-	-	-	-	-	0.0019
☐ bill_amt1	-	-	-	-	-	0.001
☐ bill_amt2	-	-	-	-	-	0.0025
☐ bill_amt3	-	-	-	-	-	0.0022
☐ bill_amt4	-	-	-	-	-	0.0014
☐ bill_amt5	-	-	-	-	-	0.0011
☐ bill_amt6	-	-	-	-	-	0.0009
☐ pay_amt1	-	-	-	-	-	0.0032
☐ pay_amt2	-	-	-	-	-	0.0009

（4）评分卡训练

Variable	Selected	Bin Id	Variable/Bin	Const.	Weight		WOE	Importance	Train				
					Unscaled	Scaled			Total	Positive	Negative	% Pos	% Neg
Intercept	-	-	-	-	-1.254	531	-	-	-	-	-	-	-
pay_0	✓	-	-	-	0.789	-	-	4.445e-2	-	-	-	-	-
	-	0	(-inf,-1]	-	-0.34	-20	-0.415	-	1648	266	1382	19.65	29.75
	-	1	(-1,0]	-	-0.51	-29	-0.706	-	2943	370	2573	27.33	55.38
	-	2	(0,1]	-	0.474	27	0.562	-	757	256	501	18.91	10.78
	-	3	(1,2]	-	1.618	93	2.12	-	562	398	164	29.39	3.53
	-	4	(2,+inf)	-	1.747	101	2.134	-	90	64	26	4.73	0.56
	-	-2	ELSE	-	0	0	-	-	0	0	0	0	0
	-	-1	NULL	-	0	0	-	-	0	0	0	0	0
limit_bal	✓	-	-	-	0.453	-	-	2.414e-3	-	-	-	-	-
	-	0	(-inf,30000]	-	0.299	17	0.743	-	803	305	498	22.53	10.72
	-	1	(30000,50000]	-	0.124	7	0.269	-	710	196	514	14.48	11.06
	-	2	(50000,70000]	-	0.168	10	0.208	-	337	89	248	6.57	5.34
	-	3	(70000,100000]	-	0.058	3	0.161	-	639	163	476	12.04	10.25
	-	4	(100000,140...	-	0.02	1	0.033	-	579	134	445	9.9	9.58
	-	5	(140000,180...	-	-0.126	-7	-0.398	-	684	112	572	8.27	12.31
	-	6	(180000,210...	-	-0.139	-8	-0.222	-	486	92	394	6.79	8.48

评分卡训练的结果图如下:

评分卡的精髓是将复杂的比较难理解的一些模型权重用符合业务标准的分数表示。

- intercepy表示的是截距
- Unscaled是原始的权重值
- Scaled是分数更改指标，比如对于pay_0这个特征，如果特征落在(-1,0]之间分数就减29，如果特征落在 (0 , 1]之间分数就加上27.
- importance表示每个特征对于结果的影响大小，数值越大表示影响越大

(5) 评分卡预测

展示每个预测结果的最终评分，在本案例中表示的是每个用户的信用评分。

序号	payment_next_month	prediction_score	prediction_prob	prediction_detail
1	0	499	0.14314626458020613	{ "0":0.8568537354,"1":0.1431462646}
2	0	564	0.3367775480162267	{ "0":0.6632224520,"1":0.3367775480}
3	0	555	0.3035873747480541	{ "0":0.6964126253,"1":0.3035873747}
4	1	519	0.18818103244164777	{ "0":0.8118189676,"1":0.1881810324}
5	1	651	0.7013570482913543	{ "0":0.2986429517,"1":0.7013570483}
6	0	502	0.1474992646536902	{ "0":0.8525007353,"1":0.1474992647}
7	1	560	0.3199046397072833	{ "0":0.6800953603,"1":0.3199046397}
8	0	435	0.05207880036730361	{ "0":0.9479211996,"1":0.0520788004}
9	0	491	0.12535852489673346	{ "0":0.8746414751,"1":0.1253585249}

结论

基于用户的信用卡消费记录，最终通过评分卡模型的训练，我们在评分卡预测中可以拿到每个用户的最终信用评分，这个评分可以应用到其它的各种贷款或者金融相关的征信领域中去。

一、背景

心脏病是人类健康的头号杀手。全世界1 / 3的人口死亡是因心脏病引起的，而我国，每年有几十万人死于心脏病。所以，如果可以通过提取人体相关的体侧指标，通过数据挖掘的方式来分析不同特征对于心脏病的影响，对于预测和预防心脏病将起到至关重要的作用。本文将会通过真实的数据，通过阿里云机器学习平台搭建心脏病预测案例。

二、数据集介绍

数据源：UCI开源数据集heart_disease针对美国某区域的心脏病检查患者的体测数据，共303条数据。具体字段如下表：

字段名	含义	类型	描述
age	年龄	string	对象的年龄，数字表示
sex	性别	string	对象的性别，female和male
cp	胸部疼痛类型	string	痛感由重到无 typical、atypical、 non-anginal、 asymptomatic
trestbps	血压	string	血压数值
chol	胆固醇	string	胆固醇数值
fbs	空腹血糖	string	血糖含量大于 120mg/dl为true，否 则为false
restecg	心电图结果	string	是否有T波，由轻到重 为norm、hyp
thalach	最大心跳数	string	最大心跳数
exang	运动时是否心绞痛	string	是否有心绞痛，true为 是，false为否
oldpeak	运动相对于休息的ST depression	string	st段压数值
slop	心电图ST segment的 倾斜度	string	ST segment的 slope，程度分为 down、flat、up
ca	透视检查看到的血管数	string	透视检查看到的血管数
thal	缺陷种类	string	并发种类，由轻到重 norm、fix、rev
status	是否患病	string	是否患病，buff是健康 、sick是患病

三、数据探索流程

数据挖掘流程如下：



整体实验流程：



1.数据预处理

数据预处理也叫作数据清洗，主要在数据进入算法流程前对数据进行去噪、填充缺失值、类型变换等操作。本次实验的输入数据包括14个特征和1个目标队列。需要解决的场景是根据用户的体检指标预测是否会患有心脏病，每个样本只有患病或不患病两种，是分类问题。因为本次分类实验选用的是线性模型逻辑回归，要求输入的特征都是double型的数据。输入数据展示：

数据探查 - heart_disease_prediction - (仅显示前一百条)

age ▲	sex ▲	cp ▲	trestbps ▲	chol ▲	fbs ▲	restecg ▲	thalach ▲	exang ▲	oldpeak ▲	slop ▲	ca ▲	thal ▲	status ▲	style ▲
63.0	male	ang...	145.0	233.0	true	hyp	150.0	false	2.3	down	0.0	fix	buff	H
67.0	male	asy...	160.0	286.0	false	hyp	108.0	true	1.5	flat	3.0	norm	sick	S2
67.0	male	asy...	120.0	229.0	false	hyp	129.0	true	2.6	flat	2.0	rev	sick	S1
37.0	male	not...	130.0	250.0	false	norm	187.0	false	3.5	down	0.0	norm	buff	H
41.0	fem	abn...	130.0	204.0	false	hyp	172.0	false	1.4	up	0.0	norm	buff	H
56.0	male	abn...	120.0	236.0	false	norm	178.0	false	0.8	up	0.0	norm	buff	H
62.0	fem	asy...	140.0	268.0	false	hyp	160.0	false	3.6	down	2.0	norm	sick	S3
57.0	fem	asy...	120.0	354.0	false	norm	163.0	true	0.6	up	0.0	norm	buff	H
63.0	male	asy...	130.0	254.0	false	hyp	147.0	false	1.4	flat	1.0	rev	sick	S2
53.0	male	asy...	140.0	203.0	true	hyp	155.0	true	3.1	down	0.0	rev	sick	S1

我们看到有很多数据是文字描述的，在数据预处理的过程中我们需要根据每个字段的含义将字符型转为数值。

1) 二值类的数据二值类的比较容易转换，如sex字段有两种表现形式female和male，我们可以将female表示成0，把male表示成1。

2) 多值类的数据比如cp字段，表示胸部的疼痛感，我们可以通过疼痛的由轻到重映射成0~3的数值。


数据的预处理通过sql脚本来实现，具体请参考SQL脚本-1组件，

```
select age,
(case sex when 'male' then 1 else 0 end) as sex,
(case cp when 'angina' then 0 when 'notang' then 1 else 2 end) as cp,
trestbps,
chol,
(case fbs when 'true' then 1 else 0 end) as fbs,
(case restecg when 'norm' then 0 when 'abn' then 1 else 2 end) as restecg,
thalach,
(case exang when 'true' then 1 else 0 end) as exang,
oldpeak,
(case slop when 'up' then 0 when 'flat' then 1 else 2 end) as slop,
ca,
(case thal when 'norm' then 0 when 'fix' then 1 else 2 end) as thal,
(case status when 'sick' then 1 else 0 end) as ifHealth
from ${t1};
```

2.特征工程

特征工程主要是包括特征的衍生、尺度变化等。本例中有两个组件负责特征工程的部分。

1) 过滤式特征选择主要是通过这个组件判断每个特征对于结果的影响，通过信息熵和基尼系数来表示，可以通过查看评估报告来显示最终的结果。



2) 归一化因为本次实验选择的是通过逻辑回归二分类来进行模型训练，需要每个特征去除量纲的影响。归一化的作用是将每个特征的数值范围变为0到1之间。归一化的公式为 $result = (val - min) / (max - min)$ 。归一化结果：
数据探查 - pai_temp_2954_36756_1 - (仅显示前一百条)

sex ▲	cp ▲	fbs ▲	restecg ▲	exang ▲	slop ▲	thal ▲	ifheath ▲	age ▲	trestbps ▲	chol ▲	thalach ▲	oldpeak ▲
1	0	1	1	0	1	0.5	0	0.70...	0.4811320...	0.244...	0.603053...	0.370967...
1	1	0	1	1	0.5	0	1	0.79...	0.6226415...	0.365...	0.282442...	0.241935...
1	1	0	1	1	0.5	1	1	0.79...	0.2452830...	0.235...	0.442748...	0.419354...
1	0.5	0	0	0	1	0	0	0.16...	0.3396226...	0.283...	0.885496...	0.564516...
0	1	0	1	0	0	0	0	0.25	0.3396226...	0.178...	0.770992...	0.225806...
1	1	0	0	0	0	0	0	0.5625	0.2452830...	0.251...	0.816793...	0.129032...
0	1	0	1	0	1	0	1	0.6875	0.4339622...	0.324...	0.679389...	0.580645...
0	1	0	0	1	0	0	0	0.58...	0.2452830...	0.520...	0.702290...	0.096774...
1	1	0	1	0	0.5	1	1	0.70...	0.3396226...	0.292...	0.580152...	0.225806...
1	1	1	1	1	1	1	1	0.5	0.4339622...	0.175...	0.641221...	0.5
1	1	0	0	0	0.5	0	0	0.58...	0.4339622...	0.150...	0.587786...	0.064516...

3.模型训练和预测

本次实验是监督学习，因为我们已经知道每个样本是否患有心脏病，所谓监督学习就是已知结果来训练模型。解决的问题是预测一组用户是否患有心脏病。

- 1) 拆分首先通过拆分组件将数据分为两部分，本次实验按照训练集和预测集7：3的比例拆分。训练集数据流入逻辑回归二分类组件用来训练模型，预测集数据进入预测组件。
- 2) 逻辑回归二分类逻辑回归是一个线性模型，在这里通过计算结果的阈值实现分类。具体的算法详情推荐大家在网上或者书籍中自行了解。逻辑回归训练好的模型可以在模型页签中查看。

逻辑回归输出

字段名 ▲	权重	
	1 ▲	0 ▲
sex	1.473569994686197	-
cp	2.730064736238172	-
fbs	-0.6007338270729394	-
restecg	0.8990240712157691	-
exang	0.9026382341453308	-
slop	1.041821068646534	-
thal	1.562393603912368	-
age	-0.4278050593226199	-

1、PAI平台提供的逻辑回归可用于多分类的，采取的策略是OneVsAll，因此在多分类的情况下，会出现多个方程，每个方程针对目标特征的某个value值，即权重（weight）下方对应的列名；

2、逻辑回归的完整公式为： $\sigma(z) = 1 / (1 + \exp(-z))$ ； $z = w_0 + w_1 * x_1 + w_2 * x_2 + \dots + w_m * x_m$ 。（其中 $x_1, x_2, \dots, x_m$ 是某样本数据的各个特征， $w_1, w_2, \dots$ 是特征的权重值）

关闭

3)预测预测组件的两个输入分别是模型和预测集。预测结果展示的是预测数据、真实数据、每组数据不同结果的概率。

4.评估

通过混淆矩阵组件可以评估模型的准确率等参数，

混淆矩阵

混淆矩阵 比例矩阵 统计信息

模型 ▲	正确数 ▲	错误数 ▲	总计 ▲	准确率 ▲	精确率 ▲	召回率 ▲	F1指标 ▲
0	40	8	48	84.146%	83.333%	88.889%	86.022%
1	29	5	34	84.146%	85.294%	78.378%	81.69%

通过此组件可以方便的通过预测的准确性来评估模型。

四.总结

通过以上数据探索的流程我们可以得到以下的结论。

- 1) 特征权重我们可以通过过滤式特征选择得到每个特征对于结果的权重。

featname ▲	weight ▲
thalach	0.16569171224597157
oldpeak	0.14640697618779352
thal	0.13769166559906015
ca	0.11467097546217575
chol	0.10267709576600859
age	0.07876430484527841
trestbps	0.0772599125640569
slop	0.07702762609078306
restecg	0.015246832497405105
cp	0.0037507283721422424
exang	0
fbs	0
sex	0

-可以看出thalach(心跳数)对于是否发生心脏病影响最大。

-性别对于心脏病没有影响

2) 模型效果通过上文提供的14个特征，可以达到百分之八十多的心脏病预测准确率。模型可以用来做预测，辅助医生预防和治疗心脏病。

五、其它

参与讨论：云栖社区公众号

免费体验：阿里云数加机器学习平台

下期预告：机器学习图算法最短路径的计算

（本文数据为虚构，仅供实验。本实验拟在介绍文本类组件，具体有意实现效果的提升请联系我们，我们提供完整解决方案和商业合作。）

一、背景

新闻分类是文本挖掘领域较为常见的场景。目前很多媒体或是内容生产商对于新闻这种文本的分类常常采用人肉打标的方式，消耗了大量的人力资源。本文尝试通过智能的文本挖掘算法对于新闻文本进行分类。无需任何人肉打标，完全由机器智能化实现。

本文通过PLDA算法挖掘文章的主题，通过主题权重的聚类，实现新闻自动分类。包括了分词、词型转换、停用词过滤、主题挖掘、聚类等流程。

二、数据集介绍

具体字段如下：


字段名	含义	类型	描述
category	新闻类型	string	体育、女性、社会、军事、科技等
title	标题	string	新闻标题
content	内容	string	新闻内容

数据截图：



三、数据探索流程

首先，实验流程图：



实验可以大致分为五个模块，分别是增加序号列、停用词过滤、分词及词频统计、文本主题挖掘、结果分析和评估。

1.增加序号列

本文的数据源输入是以单个新闻为单元，需要增加ID列来作为每篇新闻的唯一标识，方便下面的算法进行计算。

2.分词及词频统计

这两步都是文本挖掘领域最常规的做法，首先利用分词控件对于content字段，也就是新闻内容进行分词。去除过滤词之后（过滤词一般是标点符号及助语），对于词频进行统计。如下图：

append_id ▲	word ▲	count ▲
0	山	1
0	分分	1
0	别墅	1
0	勇敢	1
0	包装	1
0	博爱	1
0	却	1
0	又	2
0	发	1
0	句	1

3.停用词过滤

停用词过滤功能用于过滤输入的停用词词库，一般过滤标点符号以及对于文章影响较少的助语等。

4.文本主题挖掘

使用PLDA文本挖掘组件需要先将文本转换成三元形式，append_id是每篇新闻的唯一标识，key_value字段中冒号前面的数字表示的是单词抽象成的数字标识，冒号后面是对应的单词出现的频率。三元组组件生成结果如下：

append_id ▲	key_value ▲
213	337:1,412:1,667:3,861:1,1096:2,1582:1,1693:1,2109:1,2283:1,2371:1,2659:1,3054:3,3092:1,3232:1,4170:1,4376:1,4889:1,5206:1,5427:1,5595:1,5692:1,5739:1,6116:1,6133:1,6529:...
216	10:1,127:1,436:1,675:1,891:1,915:1,1096:2,1468:1,1757:1,2013:1,2109:1,2562:1,2783:1,3054:1,3400:1,3427:1,3443:1,3459:1,4597:1,6116:1,6183:1,6190:1,6529:1,6552:1,6871:1,7...
219	228:1,339:1,394:1,430:2,539:3,862:1,926:1,1224:1,1421:1,1488:2,1528:1,1670:2,1822:1,1909:2,2109:1,2301:1,2325:1,2411:1,2783:1,2959:1,2983:2,3209:1,4168:1,4188:1,5111:1,5...
221	10:1,18:1,200:1,387:1,412:1,436:1,450:2,472:4,555:2,563:2,637:1,639:2,667:1,813:1,856:1,913:1,1416:1,1502:1,1604:1,1636:1,2448:1,2641:2,2659:1,2929:1,3054:3,3092:2,3100:1,...
224	1582:1,3288:1,3702:1,5582:1,5932:1,6077:1,6249:1,6430:1,6529:1,6734:1,7638:1,8888:1,9418:1,9425:1,9925:1,10017:1,10176:1,11681:1,11683:1,12744:2,12748:2
227	10:1,368:1,539:1,675:1,915:1,926:1,960:1,1096:2,1423:1,1757:1,1759:1,2057:1,2109:1,2812:1,3024:1,3092:1,3181:1,3359:1,3591:1,4514:1,5464:1,6077:1,6116:1,6295:1,6529:1,65...
23	10:10,18:3,23:1,30:1,38:1,99:2,102:6,146:1,181:2,183:1,234:1,299:1,430:1,436:1,535:1,539:2,667:2,753:1,813:5,854:1,917:1,920:1,922:1,969:5,978:2,996:1,998:1,1001:4,1096:1,11...
232	12:1,13:1,18:1,69:2,146:1,200:1,234:2,329:1,370:2,565:2,571:2,605:1,608:2,667:7,813:3,891:5,1008:5,1065:1,1096:1,1104:1,1189:5,1190:2,1293:1,1572:1,1636:1,1816:1,2117:1,21...
235	12:2,13:2,18:1,88:1,204:1,478:1,523:1,558:1,575:1,606:1,667:2,670:1,754:2,803:1,872:1,921:1,1119:1,1398:2,1421:1,1498:1,1704:1,1947:1,2109:2,2132:1,2352:1,2783:3,3019:1,30...
238	10:3,202:2,539:1,667:1,892:1,1096:3,1127:1,1584:1,1806:2,2109:1,2122:1,2143:1,3024:1,3054:2,3364:1,3701:2,3765:1,3879:1,3984:1,5500:1,5685:1,6116:1,6529:1,6832:1,7460:1,...
240	10:1,107:1,115:1,146:1,412:1,430:1,450:2,596:1,667:1,800:1,931:1,1478:1,1584:1,1604:1,1652:2,1648:1,2352:1,2641:1,2676:1,2783:1,3000:2,3018:1,3054:2,3078:1,3577:1,3901:1,...

在上一步完成了文本转数字的过程，下一步数据进入PLDA算法。PLDA算法又叫主题模型，算法可以定位代表每篇文章的主题的词语。本次试验设置了50个主题，PLDA有六个输出桩，第五个输出桩输出结果显示的是每篇文章对应的每个主题的概率。如图：

docid	topic_0	topic_1	topic_2	topic_3	topic_4	topic_5	topic_6	topic_7	topic_8	topic_9	topic_10	topic_11	topic_12
0	0.0015625	0.0015625	0.0015625	0.0171875	0.0015625	0.0484375	0.0015625	0.0015625	0.0015625	0.0015625	0.0015625	0.0328125	0.0015625
1	0.001298...	0.014285...	0.001298...	0.014285...	0.001298...	0.001298...	0.014285...	0.001298...	0.001298...	0.014285...	0.1831168...	0.001298...	0.001298...
2	0.011224...	0.021428...	0.001020...	0.011224...	0.011224...	0.001020...	0.001020...	0.001020...	0.001020...	0.011224...	0.001020...	0.021428...	0.001020...
3	0.000884...	0.000884...	0.000884...	0.000884...	0.000884...	0.000884...	0.000884...	0.000884...	0.000884...	0.000884...	0.0716814...	0.000884...	0.000884...
4	0.039285...	0.003571...	0.003571...	0.289285...	0.003571...	0.003571...	0.003571...	0.003571...	0.003571...	0.039285...	0.003571...	0.075	0.003571...
5	0.001408...	0.001408...	0.001408...	0.001408...	0.001408...	0.001408...	0.001408...	0.001408...	0.001408...	0.043661...	0.0295774...	0.001408...	0.001408...
6	0.002736...	0.010199...	0.010199...	0.000248...	0.000248...	0.040049...	0.000248...	0.000248...	0.000248...	0.000248...	0.0201492...	0.000248...	0.000248...
7	0.000543	0.000543	0.000543	0.000543	0.000543	0.027717	0.000543	0.000543	0.000543	0.000543	0.0548913	0.000543	0.000543

5.结果分析和评估

上一步把文章从主题的维度表示成了一个向量。接下来就可以通过向量的距离实现聚类，从而实现文章分类。我们这里可以简单看一下分类的结果。查看K均值聚类组件的结果，cluster_index表示的是每一类的名称。找到第0类，一共有docid为115，292，248，166四篇文章。

docid	cluster_index
115	0
292	0
248	0
166	0
116	2
210	3
8	4
15	4

通过过滤与映射组件查询115，292，248，166四篇文章。结果如下：

append_id	category	title	content
115	体育	"欧洲通...	来源：重庆晚报"欧洲通行证"考验门将每次大赛，新推出的用球都会成为球员和市场关注的焦点，此次欧洲杯的用球"欧洲通行证"估计也会让门将们大伤脑筋...
166	财经	新旗舰...	机构：周四上证指数快速回升进一步提振了市场在3000点一带进行抵抗的信心，大盘如同自由落体，直至2900点附近才出现抵抗，最终当天再...
248	体育	图文： ...	来源：体育体育讯 北京时间6月15日凌晨，08欧洲杯D组第二轮开战，在奥地利因斯布鲁克的蒂沃利球场，西班牙2比1险胜瑞典，斗牛士军团以6...
292	科技	L G第...	赛迪网讯6月30日消息，据台湾媒体报道，随着第二季度摩托罗拉在全球的手机市场的表现持续低迷，L G电子第二季度手机出货量有望突破3，000...

效果并不十分理想，将一篇财经、一篇科技的新闻跟两个体育类新闻分到一起。主要原因是细节的调优没有做，也没有做特征工程，同时数据量太小也是一个主要的因素。本文只是一个简单的案例，商业合作可以私下

联系我们，我们在文本方面我们有较完善的解决方案。

一、背景

本文实现的场景是广告的CTR预测。广告CTR预测是广告行业的典型应用，通过历史数据训练预测模型，对于每天的增量数据进行预测，找出广告的CTR符合标准的样本进行投放。整套实验使用了阿里云机器学习进行数据挖掘工作，通过大数据开发套件进行调度和推送。具体的业务场景是：通过历史数据在阿里云机器学习平台上面训练模型，通过大数据开发进行调度，每天凌晨对于每天的广告投放CTR预测，甄选出符合标准的广告推送出去。

二、数据集介绍

具体字段如下：

字段名	含义	类型	描述
id	ID	string	广告的唯一标识
age	年龄	double	广告投放人群的年龄
sex	性别	double	广告投放人群的性别，1是男，0是女
duration	时长	double	广告在界面的停留时长，以秒为单位
place	位置	double	广告投放位置，0~4，按照投放位置从上到下的顺序排列
ctr	广告CTR	double	广告点击量除以展现量，这里面大于0.03是1，其它是0
dt	partition	string	年月日格式 yyyyMMdd


数据截图：

id ▲	age ▲	sex ▲	duration ▲	place ▲	ctr ▲	dt ▲
0	49	1	9	0	0	20160919
1	17	1	3	1	1	20160919
2	44	0	4	0	0	20160919
3	14	1	9	1	0	20160919
4	44	1	5	4	0	20160919
5	10	1	9	3	1	20160919
6	42	1	7	3	0	20160919
7	51	1	3	1	1	20160919
8	18	0	3	3	0	20160919
9	39	0	8	4	1	20160919
10	45	1	3	2	0	20160919
11	57	0	8	2	0	20160919
12	14	0	7	2	1	20160919

数据是通过random算法随机生成，所以本次实验不针对结果进行评估，主要介绍实验搭建以及和大数据开发套件的调度使用。数据包含20160919、20160920的历史数据，需要针对20160921的数据预测。使用的是MaxCompute的分区表。

三、机器学习平台

首先，实验流程图：



实验可以大致分为四个模块，数据源导入（ad），数据预处理（归一化），模型训练（逻辑回归二分类），预测（预测）。

数据源导入

- ad-2是训练数据源。
- ad-1是预测源，

表选择

字段信息

表名 跨项目读表: 项目名.表名

ad

✓ 分区

参数 例如 dt=@@{yyyyMMdd-1d} ?

dt=@@{yyyyMMdd}

- 通过配置分区表的partition dt=@@{yyyyMMdd}，确定预测数据是每日的增量数据。（分区使用详情见：

https://help.aliyun.com/document_detail/30281.html?spm=5176.doc30276.6.126.3kX7OU）

中间过程

中间过程包括数据的归一化、模型预测两个步骤。模型训练是通过历史数据训练生成的预测模型。（详细原理可以参考心脏病预测案例）

预测

最终预测生成的结果表为ad_result-1,数据如下：

id ▲	prediction_result ▲	prediction_score ▲	prediction_detail ▲
400	0	0.5090281750932395	{ "0": 0.5090281750932395, "1": 0.4909718249067604 }
401	0	0.5185830406571692	{ "0": 0.5185830406571692, "1": 0.4814169593428308 }
402	0	0.5037390968394624	{ "0": 0.5037390968394624, "1": 0.4962609031605377 }
403	1	0.5136006398483877	{ "0": 0.4863993601516123, "1": 0.5136006398483877 }
404	0	0.5032116074286588	{ "0": 0.5032116074286588, "1": 0.4967883925713412 }
405	0	0.5170683273721821	{ "0": 0.5170683273721821, "1": 0.4829316726278179 }
406	1	0.5561919238468677	{ "0": 0.4438080761531323, "1": 0.5561919238468677 }
407	0	0.51090881729545	{ "0": 0.51090881729545, "1": 0.48909118270455 }

- prediction_result包含每个广告id是否被点击，被点击是1，不被点击为0。

- prediction_score表示对应被点击概率


四、调度模块



进入数加的数据开发应用：

(1)新建 workflow 任务

在画布中可以拖动机器学习组件和ODPS_SQL组件进行工作流的搭建。




双击“广告预测”组件进入对应的机器学习模块，选择需要调度的机器学习实验：

选择机器学习实验: [重新加载该机器学习的代码](#) [在机器学习平台中查看实验](#)

机器学习代码


```
<?xml version="1.0" encoding="UTF-8"?>
<job>
  <subJobs>
    <sql>
      <endpoint>http://service.odps.aliyun.com/api</endpoint>
      <project>garvin_test</project>
      <subJobId>1</subJobId>
      <sql>drop table if exists pai_temp_11786_219337_2</sql>
      <useProductKey>false</useProductKey>
    </sql>
    <sql>
      <endpoint>http://service.odps.aliyun.com/api</endpoint>
      <project>garvin_test</project>
      <subJobId>2</subJobId>
      <sql>drop table if exists pai_temp_11786_219337_1</sql>
      <useProductKey>false</useProductKey>
    </sql>
    <odpscmd>
      <endpoint>http://service.odps.aliyun.com/api</endpoint>
      <project>garvin_test</project>
      <subJobId>3</subJobId>
      <appName>dmsdp</appName>
      <command>PAI -name normalize -project algo_public -DoutputParaTableName="pai_temp_11786_219337_2" -
```

- 返回，双击“每日预测值”组件，配置每日需要推送的信息，这里只需要推送预测结果是“被点击的



- 广告”，
- 选择需要调度的时间，这里我选择每日的凌晨0点进行训练和推送信息。


- 点击“提交”按钮，即可在运维中心查看实验的运行状态。调度从第二天才正式开始，进入运维中心。可以查看实验的日志。



背景

我们通过之前的案例已经为大家介绍了如何通过常规的体检数据预测心脏病的发生，请见 <https://yq.aliyun.com/articles/54260>。通过前文的案例我们可以生成一个算法模型，通过向这个模型输入用

户实时的体检数据就会返回用户患有心脏病的概率。那么我们该如何搭建这套实时监测用户健康情况的服务呢？PAI最新推出的在线预测服务帮您实现。目前，机器学习PAI已经支持实验模型一键部署到云端生成API，通过向这个API推送用户的实时体检数据，就可以实时拿到反馈结果，做到心脏状况的云端的在线监测。




下面看下如何实现这套在线

预测服务。


1.选择部署模型

我们以上文链接提到的心脏病预测案例为例，实验生成一个逻辑回归模型，是用在线预测可以在当前实验点击“部署”按钮，选择“在线预测部署”。





2.配置模型部署信息



进入模型配置页：

选择对应的项目空间，如果是第一次使用需要开通在线预测权限，权限申请是实时开通。下面详细解释instance的定义：

每个项目默认包含30个instance，可提工单扩容。删除已部署模型会释放当前模型的instance。

instance决定模型的QPS，每个instance为1核2G内存。

- 单个模型的instance部署限制是[1,15]。


3.模型管控

模型部署完成可以进入如下界面进行管理，新部署模型可以在“查看模型详情”进行查看。



部署在线模型”里进行管理，

已经部署的模型可以在“已



模型管理界面，版本表示的是同一模型多次部署的区分，通过下图红框可以拿到模型所在的项目和模型名称：

在线预测部署

✕

当前模型状态: 部署成功

当前版本: 0

部署时间: 2017-06-22 11:19:12 请查看页面下方信息进行

接口调用。如需更新, 请点击:

重新部署

删除当前版本

模型调试

查看历史版本信息, 请点击版本进行切换, 重新部署新增预测服务, 不会覆盖原有服务

接口模式

返回样例

帮助: https://help.aliyun.com/document_detail/45395.html

预测服务endpoint: <http://prediction.odps.aliyun.com>

部署project: shequ

在线模型名称: xlab_m_logisticregress_520728_v0

接口方式: Restful Api支持Json和Protobuf

返回格式: JSON/XML

接口样例:

POST

http://prediction.odps.aliyun.com/projects/shequ/onlinemodels/xlab_m_logisticregress_520728_v0

HTTP/1.1

Authorization: ODPS

AccessId:AccessKey

Date: Tue, 31 Mar 2015 06:32:27 GMT

Content-Type: application/json

4.模型调试

模型调试页面可以帮助用户了解在线预测请求参数的书写规范, 进入模型调试页面。

API调试: 机器学习

您可以通过调用API来实现对您为数加订购的官方服务的调用, 这个工具帮助您快速入门, 详情请查看[机器学习API说明](#)、[数加平台API校验规则](#) (数加平台相关)。

接口名称: prediction

请求方法: POST

请求地址: https://dtplus-cn-shanghai.data.aliyuncs.com/dataplus_261422/pai/prediction
请求地址可以自行加上入参, 例如<http://example.com?param1=123¶m2=456>

请求Body: 请填写Http请求Body, 例如: {"Test":123}

Access Key ID: 阿里云Access Key ID
请使用团队管理员的AK, 管理员帐号可以到[成员管理](#)查看。阿里云AK可到[Access Key管理](#)查看。

Access Key Secret: 阿里云Access Key Secret

调试接口

返回结果:

- 请求地址: [https://dtplus-cn-shanghai.data.aliyuncs.com/dataplus_261422/pai/prediction/projects/\\$project名称/onlinemodels/\\$模型名称](https://dtplus-cn-shanghai.data.aliyuncs.com/dataplus_261422/pai/prediction/projects/$project名称/onlinemodels/$模型名称)
- 请求body为json串, 以本文逻辑回归算法为例, 需要填写每个特征的信息, 特征名字需要与模型表特

征名对应，常数列不用写。dataValue表示预测集对应特征的取值。dataType表示数值类型，dataType定义如下：

数据类型	dataType
bool	1
int32	10
int64	20
float	30
double	40
string	50

5.预测结果

现在我们已经配置好了服务，接下来只要编辑服务的body部分并且发送请求即可获得预测结果。我们假设用户的实时性别、血压、心跳波动等参数都是1，推送以下数据。本案例body范例：

```
{
  "inputs": [
    {
      "sex": {
        "dataType": 40,
        "dataValue": 1
      },
      "cp": {
        "dataType": 40,
        "dataValue": 1
      },
      "fbs": {
        "dataType": 40,
        "dataValue": 1
      },
      "restecg": {
        "dataType": 40,
        "dataValue": 1
      },
      "exang": {
        "dataType": 40,
        "dataValue": 1
      },
      "slop": {
        "dataType": 40,
        "dataValue": 1
      },
      "thal": {
        "dataType": 40,
        "dataValue": 1
      },
      "age": {
        "dataType": 40,
```

```

"dataValue": 1
},
"trestbps": {
"dataType": 40,
"dataValue": 1
},
"chol": {
"dataType": 40,
"dataValue": 1
},
"thalach": {
"dataType": 40,
"dataValue": 1
}
}
]
}

```

可以获得返回，返回结果显示label为1（1表示用户患病，0表示健康），并且患病概率为0.98649974...：

```

- - - - - 请求 - - - - -
- - - - - 返回 - - - - -
状态码：200
返回Body：{
  "outputs": [
    {
      "outputLabel": "1",
      "outputMulti": {
        "0": 0.01351125016100008,
        "1": 0.9864887498389999
      },
      "outputValue": {
        "dataType": 40,
        "dataValue": 0.9864887498389999
      }
    }
  ]
}
- - - - - 返回 - - - - -

```

API调用方法：https://help.aliyun.com/document_detail/30245.html

（本文数据为虚构，仅供实验）

一、背景

数据挖掘的一个经典案例就是尿布与啤酒的例子。尿布与啤酒看似毫不相关的两种产品，但是当超市将两种产品放到相邻货架销售的时候，会大大提高两者销量。很多时候看似不相关的两种产品，却会存在这某种神秘的隐含关系，获取这种关系将会对提高销售额起到推动作用，然而有时这种关联是很难通过理性的分析得到的。这时候我们需要借助数据挖掘中的常见算法-协同过滤来实现。这种算法可以帮助我们挖掘人与人以及商品与商品的关联关系。

协同过滤算法是一种基于关联规则的算法，以购物行为为例。假设有甲和乙两名用户，有a、b、c三款产品。如果甲和乙都购买了a和b这两种产品，我们可以假定甲和乙有近似的购物品味。当甲购买了产品c而乙还没有购买c的时候，我们就可以把c也推荐给乙。这是一种典型的user-based情况，就是以user的特性做为一种关联。

本文的业务场景如下：通过一份7月份前的用户购物行为数据，获取商品的关联关系，对用户7月份之后的购买形成推荐，并评估结果。比如用户甲某在7月份之前买了商品A，商品A与B强相关，我们就在7月份之后推荐了商品B，并探查这次推荐是否命中。

二、数据集介绍


数据源：本数据源为天池大赛提供数据，数据按时间分为两份，分别是7月份之前的购买行为数据和7月份之后的。具体字段如下：

字段名	含义	类型	描述
user_id	用户编号	string	购物的用户ID
item_id	物品编号	string	被购买物品的编号
active_type	购物行为	string	0表示点击，1表示购买，2表示收藏，3表示购物车
active_date	购物时间	string	购物发生的时间

数据截图：


10944750	8689	2	5月2日
10944750	25687	2	5月8日
10944750	7150	1	6月7日
10944750	13451	0	6月4日
10944750	13451	0	6月4日
10944750	13451	0	6月4日
10944750	13451	0	6月4日
10944750	13451	0	6月4日
10944750	13451	0	6月4日

三、数据探索流程



首先，实验流程图：

1. 协同过滤推荐流程



首先输入的数据源是7月份之前的购物行为数据，通过SQL脚本取出用户的购买行为数据，进入协同过滤组件。协同过滤的组件设置中把TopN设置成1，表示每个item返回最相近的item和它的权重。通过购买行为，分析出哪些商品被同一个user购买的可能性最大。设置图如下：

② 数据格式 可选

user-item-payload

相似度类型 可选

wbcosine

② TopN 可选


1

协同过滤结果，表示的是商品的关联性，itemid表示目标商品，similarity字段的冒号左侧表示与目标关联性高的商品，右边表示概率：

itemid ▲	similarity ▲
1000	15584:0.2747133918
10014	18712:0.05229603127
10066	3228:0.2650900672
1008	24507:1
10082	18024:0.1781525919
1010	18024:0.2104947227
10133	14020:0.2070609237
1015	18024:0.2104947227
10151	26288:0.4366713611
10171	11080:0.2401992435

2.推荐

上述步骤介绍了如何生成强关联商品的对应列表。这里使用了比较简单的推荐规则，比如用户甲某在7月份之前买了商品A，商品A与B强相关，我们就在7月份之后推荐了商品B，并探查这次推荐是否命中。这个步骤是通过下图实现的：



3.结果统计



上面是统计模块，左边的全表统计展示的是根据7月份之前的购物行为生成的推荐列表，去重后一共18065条。右边的统计组件显示一共命中了90条。

四、推荐系统反思

根据上文的统计结果可以看出，本次试验的推荐效果并不理想，原因在如下几方面。

1) 首先本文只是针对了业务场景大致介绍了协同过滤推荐的用法。很多针对于购物行为推荐的关键点都没有处理，比如说时间序列，购物行为一定需要注意对于时效性的分析，跨度达到几个月的推荐不会有好的效果。其次没有注意推荐商品的属性，本文只考虑了商品的关联性，没有考虑商品是否为高频或者是低频商品，比如说用户A上个月买了个手机，A下个月就不大会继续购买手机，因为手机是低频消费品。

2) 基于关联规则的推荐很多时候最好是作为补充，真正想提高准确率还是要依靠机器学习算法训练模型的方式。

五、其它

参与讨论：云栖社区公众号

免费体验：阿里云数加机器学习平台

往期文章：


【玩转数据系列一】人口普查统计案例

【玩转数据系列二】机器学习应用没那么难，这次教你玩心脏病预测

【玩转数据系列三】利用图算法实现金融行业风控

一、背景

感谢大家关注玩转数据系列文章，我们希望通过在阿里云机器学习平台上提供demo数据并搭建相关的实验流程的方式来帮助大家学习如何通过算法来挖掘数据中的价值。本系列文章包含详细的实验流程以及相关的文档教程，欢迎大家进入阿里云数加机器学习平台体验。实验案例请在新建实验页签查看，如下图。



本章作为玩转数据系列的开篇，先提供一个简单的案例给大家热身。通过截取一份人口普查的数据，对学历和收入进行统计和分析。主要目的是帮助大家学习阿里云机器学习实验的搭建流程和组件的使用方式。任何关于阿里云机器学习方面的交流欢迎访问我们的云栖社区公众号。

二、数据集介绍


数据源：UCI开源数据集Adult针对美国某区域的一次人口普查结果，共32561条数据。具体字段如下表：

字段名	含义	类型
age	年龄	double
workclass	工作类型	string
fnlwgt	序号	string
education	教育程度	string
education_num	受教育时间	double
marital_status	婚姻状况	string
occupation	职业	string
relationship	关系	string
race	种族	string
sex	性别	string
capital_gain	资本收益	string

capital_loss	资本损失	string
hours_per_week	每周工作小时数	double
native_country	原籍	string
income	收入	string

三、数据探索流程

选中人口统计demo，从模型生成实验，如下图：



使用方式：

- 用户通过从左边列表拖拽组件到试验区域搭建实验流程
- 在配置区域对每个组件的参数进行设置

1.数据导入

机器学习平台的底层计算式阿里云分布式计算系统MaxCompute（原名ODPS），所以实验数据需要先导入到ODPS表里，用户可以通过读ODPS表（图中的数据源-人口统计）组件导入数据。上传成功后，右键组件可以


数据探查 - adult_statistics_demo - (仅显示前一百条)

age	workclass	fnlwgt	education	education_num	marital_status	occupation	relationship	race	sex	capital_gain	capital_loss
39	State-gov	77516	Bachelors	13	Never-married	Adm-clerical	Not-in-family	White	Male	2174	0
50	Self-emp-n...	83311	Bachelors	13	Married-civ-spouse	Exec-manag...	Husband	White	Male	0	0
38	Private	215646	HS-grad	9	Divorced	Handlers-cle...	Not-in-family	White	Male	0	0
53	Private	234721	11th	7	Married-civ-spouse	Handlers-cle...	Husband	Black	Male	0	0
28	Private	338409	Bachelors	13	Married-civ-spouse	Prof-specialty	Wife	Black	Fem...	0	0
37	Private	284582	Masters	14	Married-civ-spouse	Exec-manag...	Wife	White	Fem...	0	0
49	Private	160187	9th	5	Married-spouse-a...	Other-service	Not-in-family	Black	Fem...	0	0
52	Self-emp-n...	209642	HS-grad	9	Married-civ-spouse	Exec-manag...	Husband	White	Male	0	0
31	Private	45781	Masters	14	Never-married	Prof-specialty	Not-in-family	White	Fem...	14084	0
42	Private	159449	Bachelors	13	Married-civ-spouse	Exec-manag...	Husband	White	Male	5178	0
37	Private	280464	Some-college	10	Married-civ-spouse	Exec-manag...	Husband	Black	Male	0	0
30	State-gov	141297	Bachelors	13	Married-civ-spouse	Prof-specialty	Husband	Asian...	Male	0	0
23	Private	122272	Bachelors	13	Never-married	Adm-clerical	Own-child	White	Fem...	0	0
32	Private	205019	Assoc-acdm	12	Never-married	Sales	Not-in-family	Black	Male	0	0
40	Private	121772	Assoc-acdm	11	Married-civ-spouse	Craft-repair	Husband	Asian...	Male	0	0
34	Private	245487	Assoc-acdm	4	Married-civ-spouse	Transport-mo...	Husband	Amer...	Male	0	0
26	Self-emp-n...	176756	HS-grad	9	Never-married	Formin-fabinc...	Own-child	White	Male	0	0


查看数据，如下图：

2.理解数据

数据导入后就可以对数据进行了分析，整个实现从纵向看分为三个部分。



其中全表统计和数值分布统计是帮助用户更好的理解一份数据，理解一份数据是符合泊松分布或是高斯分布,连续或是离散的对之后的算法的选择会有一定帮助（具体的对照关系在之后的文章会详细介绍）。阿里云机器学习的每个套件都提供了可视化显示结果的功能，下图是数值统计的直方图组件结果，可以清楚地看到每个输入数值的分布情况。



3.统计不同学历的人员的收入情况

每个人都想增加收入，都想知道哪些因素对收入的影响最大。这些问题都可以通过提取特征，利用机器学习算法训练来得到。本文主要目的是简单介绍一下机器学习平台的使用方法，这里简单的针对不同学历的人员的收入做一下统计。

(1)数据的预处理

我们看到在收入统计的这条线上，数据流入的第一个组件是SQL脚本（如下图），机器学习平台提供SQL脚本对于数据进行处理。这里是将string型的income字段转换成二值型的0和1的形式。0表示年收入在50K以下，1表示年收入在50K以上。这种将文本数据数值化是机器学习特征处理的常用方式，以后会经常用到这种方式。




(2)过滤与映射

这一步主要是通过过滤与映射组件将数据按照学历分为三部分，分别是博士、硕士和学士。过滤与映射底层是SQL语法，支持where过滤条件，用户通过在右边的配置栏填写过滤条件即可。



(3)统计结果

通过每个百分位组件就可以方便的得到每个分类下的收入比例。下图是调成折线图的展示效果,结果中为0的点也就是年收入在50K以下的人群占比例百分之25左右。



结合三个百分位组件就可以得到如下图结果。

学历	年收入>50K比例
博士	75%
硕士	57%
学士	42%

四、其它

- 参与讨论：云栖社区公众号
- 免费体验：阿里云数加机器学习平台

下期预告：利用机器学习算法预测患者是否患有心脏病
(本文数据为实验用例)

一、背景

母亲是老师反而会对孩子的学习成绩造成不利影响？能上网的家庭，孩子通常能取得较好的成绩？影响孩子成绩的最大因素居然是母亲的学历？本文通过机器挖掘算法和中学真实的学生数据为您揭秘影响中学生学业的关键因素有哪些。

本文的数据采集于某中学在校生的家庭背景数据以及在校行为数据。通过逻辑回归算法生成离线模型和学业指标评估报告，并且可以对学生的期末成绩进行预测。同时，生成在线预测API，可以通过API把训练好的离线模型应用到在线的业务场景中。

二、数据集介绍

数据集由25个特征和一个打标数据构成，
具体字段如下：

字段名	含义	类型	描述
-----	----	----	----


sex	性别	string	F是女，M表示男
address	住址	string	U表示城市，R表示乡村
famsize	家庭成员数	string	LE3表示少于三人，GT3多于三人
pstatus	是否与父母住在一起	string	T住在一起，A分开
medu	母亲的文化水平	string	从0~4逐步增高
fedu	父亲的文化水平	string	从0~4逐步增高
mjob	母亲的工作	string	分为教师相关、健康相关、服务业
fjob	父亲的工作	string	分为教师相关、健康相关、服务业
guardian	学生的监管人	string	mother, father or other
traveltime	从家到学校需要的时间	double	以分钟为单位
studytime	每周学习时间	double	以小时为单位
failures	挂科数	double	挂科次数
schoolsup	是否有额外的学习辅助	string	yes or no
fumsup	是否有家教	string	yes or no
paid	是否有相关考试学科的辅助	string	yes or no
activities	是否有课外兴趣班	string	yes or no
higher	是否有向上求学意愿	string	yes or no
internet	家里是否联网	string	yes or no
famrel	家庭关系	double	从1~5表示关系从差到好
freetime	课余时间量	double	从1~5从少到多
goout	跟朋友出去玩的频率	double	从1~5从少到多
dalc	日饮酒量	double	从1~5从少到多
walc	周饮酒量	double	从1~5从少到多
health	健康状况	double	从1~5从状态差到好
absences	出勤量	double	0到93次
g3	期末成绩	double	20分制

数据截图：

sex	address	famsize	pstatus	medu	fedu	mjob	fjob	guardian	travetime	studytime	failures	schoolsup	fumsup
F	U	GT3	A	4	4	at_ho...	teacher	mother	2	2	0	yes	no
F	U	GT3	T	1	1	at_ho...	other	father	1	2	0	no	yes
F	U	LE3	T	1	1	at_ho...	other	mother	1	2	3	yes	no
F	U	GT3	T	4	2	health	services	mother	1	3	0	no	yes
F	U	GT3	T	3	3	other	other	father	1	2	0	no	yes
M	U	LE3	T	4	3	services	other	mother	1	2	0	no	yes
M	U	LE3	T	2	2	other	other	mother	1	2	0	no	no
F	U	GT3	A	4	4	other	teacher	mother	2	2	0	yes	yes
M	U	LE3	A	3	2	services	other	mother	1	2	0	no	yes
M	U	GT3	T	3	4	other	other	mother	1	2	0	no	yes
F	U	GT3	T	4	4	teacher	health	mother	1	2	0	no	yes

三、离线训练

首先，实验流程图：



数据自上到下流入，先后经历了数据数据预处理、拆分、训练、预测与评估。

1.SQL脚本-数据预处理

```

select (case sex when 'F' then 1 else 0 end) as sex,
(case address when 'U' then 1 else 0 end) as address,
(case famsize when 'LE3' then 1 else 0 end) as famsize,
(case Pstatus when 'T' then 1 else 0 end) as Pstatus,
Medu,
Fedu,

```

```

(case Mjob when 'teacher' then 1 else 0 end) as Mjob,
(case Fjob when 'teacher' then 1 else 0 end) as Fjob,
(case guardian when 'mother' then 0 when 'father' then 1 else 2 end) as guardian,
traveltime,
studytime,
failures,
(case schoolsup when 'yes' then 1 else 0 end) as schoolsup,
(case fumsup when 'yes' then 1 else 0 end) as fumsup,
(case paid when 'yes' then 1 else 0 end) as paid,
(case activities when 'yes' then 1 else 0 end) as activities,
(case higher when 'yes' then 1 else 0 end) as higher,
(case internet when 'yes' then 1 else 0 end) as internet,
famrel,
freetime,
goout,
Dalc,
Walc,
health,
absences,
(case when G3>14 then 1 else 0 end) as finalScore
from ${t1};

```

这里SQL脚本主要处理的逻辑是将文本数据结构化。比如说源数据分别有yes和no的情况，我们可以通过0表示yes，1表示no将文本数据量化。一些多种类的文本型字段，比如说Mjob，我们可以结合业务场景来抽象，比如说如果工作是teacher就表示为1，不是teacher表示为0，抽象后这个特征的意义就是表示工作是否与教育相关。对于目标列，我们按照大于18分设为1，其它为0，拟在通过训练，找出可以预测分数的模型。

2.归一化

去量纲，将所有的字段都转换成0~1之间，去除字段间大小不均衡带来的影响。结果图：

sex ▲	address ▲	famsize ▲	pstatus ▲	medu ▲	fedu ▲	mjob ▲	fjob ▲	guardian ▲	traveltime ▲	studytime ▲	failures ▲	schoolsup ▲	fumsup ▲
1	1	0	0	1	1	0	1	0	0.33333333...	0.33333333...	0	1	0
1	1	0	1	0.25	0.25	0	0	0.5	0	0.33333333...	0	0	1
1	1	1	1	0.25	0.25	0	0	0	0	0.33333333...	1	1	0
1	1	0	1	1	0.5	0	0	0	0	0.66666666...	0	0	1
1	1	0	1	0.75	0.75	0	0	0.5	0	0.33333333...	0	0	1
0	1	1	1	1	0.75	0	0	0	0	0.33333333...	0	0	1
0	1	1	1	0.5	0.5	0	0	0	0	0.33333333...	0	0	0
1	1	0	0	1	1	0	1	0	0.33333333...	0.33333333...	0	1	1
0	1	1	0	0.75	0.5	0	0	0	0	0.33333333...	0	0	1
0	1	0	1	0.75	1	0	0	0	0	0.33333333...	0	0	1
1	1	0	1	1	1	1	0	0	0	0.33333333...	0	0	1
1	1	0	1	0.5	0.25	0	0	0.5	0.66666666...	0.66666666...	0	0	1
0	1	1	1	1	1	0	0	0.5	0	0	0	0	1
0	1	0	1	1	0.75	1	0	0	0.33333333...	0.33333333...	0	0	1

3.拆分

将数据集按照8：2拆分，百分之八十用来训练模型，剩下的用来预测。

4.逻辑回归

通过逻辑回归算法训练生成离线模型。具体算法详情可以https://en.wikipedia.org/wiki/Logistic_regression

5.结果分析和评估

通过混淆矩阵可以查看模型预测的准确率。

混淆矩阵

模型 ▲	正确数 ▲	错误数 ▲	总计 ▲	准确率 ▲	召回率 ▲	F1指标 ▲
0	126	25	151	82.911%	83.444%	90.323%
1	5	2	7	82.911%	71.429%	27.027%

可以看到预测准确率为82.911%。根据逻辑回归算法的特性，我们可以通过模型系数挖掘出一些比较有意思的

实验模型

- cuiyou_dir
- students_performance
 - 逻辑回归二分类-1-...
- student_performance
- 心脏病预测案例_538
- 已保存模型

逻辑回归输出

字段名 ▲	权重	
	1 ▲	0 ▲
medu	2.196219307541352	-
fedu	-0.6209320272631076	-
travelttime	-0.1401344554844348	-
studytime	0.2427716427155365	-
failures	-1.41108855780472	-
famrel	0.07782683210201805	-
freetime	0.3700338237692014	-
goout	-0.6294895937934885	-
...	...	...

1、PAI平台提供的逻辑回归可用于多分类的，采取的策略是OneVsAll，因此在多分类的情况下，会出现多个方程，每个方程针对目标特征的某个value值，即权重（weight）下方对应的列名；

2、逻辑回归的完整公式为： $\sigma(z) = 1 / (1 + \exp(-z))$ ； $z = w_0 + w_1 * x_1 + w_2 * x_2 + \dots + w_m * x_m$ 。（其中 $x_1, x_2, \dots, x_m$ 是某样本数据的各个特征， $w_1, w_2, \dots$ 是特征的权重值）

关闭

信息，首先查看模型：

根据逻辑回归算法的算法特性，权重越大表示特征对于结果的影响越大，权重是正数表示对结果1（期末高分）正相关，权重负数表示负相关。于是我们可以挑选几个权重较大的特征进行分析。

字段名	含义	权重	分析
mjob	母亲的工作	0.7998341777833717	母亲是老师对于孩子考高分是不利的
fjob	父亲工作	1.422595764037065	如果父亲是老师，对于孩子取得好的成绩是非常有利的
internet	家里是否联网	1.070938672974736	家里联网不但不会影响成绩，还会促进孩子的学习
medu	母亲的文化水平	2.196219307541352	母亲的文化水平高低对于孩子的影响是最大的，母亲文化越高孩子学习越好。

以上结论只是从实验的很小的数据集得到的结论，仅供参考。

四、在线预测部署


生成离线模型之后，可以将离线模型部署到线上，通过调用restful-api来进行在线预测。

1.部署

右键模型-》在线部署模型-》选择cpu、memory-》部署完成



部署成功后显示



之后在API调试页即可通过填写body信息调用API，并拿到预测结果。

API调试：PAI中在线预测服务

您可以通过调用API来实现对您为数加订购的官方服务的调用。这个工具帮助你快速入门。详情请查看[PAI中在线预测服务API说明](#)、[数加平台API校验规则](#)（数加平台相关）。

* 接口名称:

* 请求方法:

* 请求地址:

请求Body:

* Access Key ID:
请使用团队管理员的AK，管理员帐号可以到[成员管理](#)查看。阿里云AK可到[Access Key管理](#)查看。

* Access Key Secret:

返回结果:

四、其它

参与讨论：云栖社区公众号

免费体验：阿里云数加机器学习平台

联系我们: aohai.lb@alibaba-inc.com

往期文章：

【玩转数据系列一】人口普查统计案例

【玩转数据系列二】机器学习应用没那么难，这次教你玩心脏病预测

【玩转数据系列三】利用图算法实现金融行业风控

【玩转数据系列四】听说啤酒和尿布很配？本期教你用协同过滤做推荐

【玩转数据系列五】农业贷款发放预测

【玩转数据系列六】文本分析算法实现新闻自动分类

背景

双十一购物狂欢节马上又要到来了，最近各种关于双十一的爆品购物列表在网上层出不穷。如果是网购老司机，一定清楚通常一件商品会有很多维度的标签来展示，比如一个鞋子，它的商品描述可能会是这样的“韩都少女英伦风系带马丁靴女磨砂真皮厚底休闲短靴”。如果是一个包，那么它的商品描述可能是“天天特价包包2016新款秋冬斜挎包韩版手提包流苏贝壳包女包单肩包”。

每个产品的描述都包含非常多的维度，可能是时间、产地、款式等等，如何按照特定的维度将数以万计的产品进行归类，往往是电商平台最头痛的问题。这里面最大的挑战是如何获取每种商品的维度由哪些标签组成，如果可以通过算法自动学习出例如 地点相关的标签有“日本”、“福建”、“韩国”等词语，那么可以快速的构建标签归类体系，本文将借助PAI平台的文本分析功能，实现一版简单的商品标签自动归类系统。

数据说明

数据是在网上直接下载并且整理的一份2016双十一购物清单，一共2千多个商品描述，每一行代表一款商品的

```
1 【天天特价】韩都少女英伦风系带马丁靴女磨砂真皮厚底休闲短靴
2 拉杆箱万向轮24寸铝框皮箱旅行箱女行李箱26寸包硬箱复古登机箱20
3 韩国孔孝真欧尼oni同款2016新款mini三角小包包手机包单肩斜挎包
4 迷失麋鹿2016秋冬独家定制款女圆头粗跟靴子沙漠靴子真皮细带短靴
5 MASOOMAKE秋季中跟厚底马丁靴女英伦风 2016新款系带粗跟短靴子女
6 羊皮毛一体雪地靴代购天天特价冬保暖运动套筒松糕防滑短筒雪地鞋
7 潮2016冬季新款欧美加绒高跟女靴尖头粗跟短靴马丁靴短筒棉靴女鞋
8 2016冬韩国内增高女棉鞋保暖加绒羊羔毛高帮系带休闲鞋韩版雪地靴
9 天天特价英伦学院风粗跟小皮鞋漆皮系带复古牛津鞋尖头加绒女单鞋
10 包包2016新款女包韩版简约复古百搭链条包单肩小包包小方包斜挎包
11 天天特价包包2016新款秋冬斜挎包韩版手提包流苏贝壳包女包单肩包
12 铝框拉杆箱万向轮行李箱包男旅行箱女登机箱20/24/26寸密码箱皮箱子
13 艾迪猫2016秋冬新款潮单肩斜跨小包包韩版时尚女包斜挎女士小方包
14 天天特价欧美2016秋季新款平底单鞋懒人鞋马衔扣一脚蹬乐福鞋女鞋
15 韩国自制翻盖信封包圆环链条单肩包休闲气质百搭简约款女包斜挎包
```

标签聚合，如下图：

我们把这份数据导入PAI进行处理，具体数据上传方式可以查阅PAI的官方文档：

<https://help.aliyun.com/product/30347.html>

实验说明

数据上传完成后，通过拖拽PAI的组件，可以生成如下实验逻辑图，每一步的具体功能已经标注：



下面分模块说明下每个部分的具体功能：

1.上传数据并分词

将数据上传，由shopping_data代表底层数据存储，然后通过分词组件对数据分词，分词是NLP的基础操作，这里不多介绍。

2.增加序号列

因为上传的数据只有一个字段，通过增加序号列为每个数据增加主键，方便接下来的计算，处理后数据如下图

content ▲	append_id ▲
【 天天 特价 】韩 都 少女 英伦风 系带 马丁 靴 女 磨砂 真皮 ...	0
拉杆箱 万向轮 24 寸 铝框 皮箱 旅行箱 女 行李箱 26 寸 包 硬...	1
韩国 孔孝真 欧尼 oni 同款 2016 新款 mini 三角 小 包包 手机...	2
迷失 麋鹿 2016 秋冬 独家 定制 款 女 圆头 粗跟靴子 沙漠 靴...	3
MASOOMAKE 秋季 中跟 厚底 马丁 靴 女 英伦风 2016 新款 ...	4
羊 皮毛一体雪地靴 代购 天天 特价 冬 保暖 运动 套筒 松糕 防...	5
潮 2016 冬季 新款 欧美 加绒 高跟女靴 尖头 粗跟短靴 马丁 靴...	6
2016 冬 韩国 内增高 女 棉鞋 保暖 加绒 羊羔毛 高帮系带休闲...	7
天天 特价 英伦 学院风 粗跟 小 皮鞋 漆皮 系带 复古 牛津 鞋 ...	8
包包 2016 新款女包 韩版 简约 复古 百搭 链条包 单肩小包包 ...	9
天天 特价包包 2016 新款 秋冬 斜挎包 韩版手提包 流苏 贝壳...	10
铝框 拉杆箱 万向轮 行李箱 男 旅行箱 女 登机箱 20 / 24 / 26 ...	11
艾迪 猫 2016 秋冬新款 潮 单肩 斜跨小包包 韩版 时尚女包 斜...	12
天天 特价 欧美 2016 秋季 新款平底单鞋 懒人 鞋 马 衔 扣 一 ...	13
韩国 自制 翻盖 信封包 圆环 链条单肩包 休闲 气质 百搭 简约...	14

3.统计词频

展示的是每一个商品中出现的各种词语的个数。

4.生成词向量

使用的是word2vector这个算法，这个算法可以将每个词按照意义在向量维度展开，这个词向量有两层含义。

- 向量距离近的两个词他们的真实含义会比较相近，比如在我们的数据中，“新加坡”和“日本”都表示产品的产地，那么这两个词的向量距离会比较近。
- 不同词之间的距离差值也是有意义的，比如“北京”是“中国”的首都，“巴黎”是“法国”的首都，在训练量足够的情况下。 $|中国|-|北京|=|法国|-|巴黎|$

经过word2vector，每个词被映射到百维空间上，生成结果如下图所示：

序号	word	f0	f1	f2	f3	f4	f5	f6	f7	f8	f9	f10	f11	f12	f13
7	加厚	0.1177	0.009646	0.07124	-0.009802	0.008854	-0.1568	-0.2333	0.1643	0.0...	-0.0...	-0.2...	0.07...	-0.0...	0.02...
8	2016	0.1488	-0.1518	0.1813	0.02331	-0.03854	-0.06455	-0.001774	0.1854	0.1...	-0.0...	-0.2...	0.04...	0.1299	-0.0...
9	韩版	0.101	-0.02068	0.04436	0.02251	-0.1528	-0.2823	-0.2211	0.2521	0.0...	-0.0...	-0.2...	0.1006	0.05...	-0.0...
10	/	-0.02318	0.07028	0.189	-0.1704	0.01743	0.1096	0.1458	-0.2436	-0.0...	0.0...	0.1876	0.08...	-0.0...	0.1625
11	新款	0.1374	-0.05232	0.08965	0.09086	-0.09875	-0.2254	-0.1866	0.2333	0.0...	-0.0...	-0.189	0.07...	-0.0...	0.0253
12	6	-0.131	0.08679	0.009914	-0.3171	-0.1743	-0.1615	0.005242	-0.102	-0.0...	0.1...	-0.0...	0.1186	0.08...	0.1017
13	包邮	0.06004	0.04959	0.1578	0.1021	0.04368	0.1318	-0.05841	-0.01082	-0.0...	-0.0...	0.05...	0.1499	0.03...	0.0249
14	简约	-0.065	0.01107	0.02025	-0.1287	-0.09461	-0.1241	-0.05828	0.1292	-0.0...	0.0...	-0.0...	0.1496	0.08...	-0.1...
15	冬季	0.1803	-0.04212	0.1512	0.06145	-0.02388	-0.1422	-0.1718	0.1897	0.1...	-0.0...	-0.1...	0.08...	-0.0...	0.02...
16	秋冬	0.1078	-0.07883	0.1803	0.02858	-0.08247	-0.1859	-0.1708	0.2181	0.0...	-0.0...	-0.1...	0.1327	0.07...	-0.0...
17	-	0.04343	0.1467	0.1142	-0.2973	0.05655	0.1708	0.01833	-0.09293	-0.0...	0.1...	0.00...	0.1291	-0.0...	0.1162
18	纯棉	0.06417	-0.08088	0.07554	0.04668	-0.07626	-0.2355	-0.1062	0.1727	0.0...	-0.0...	-0.1...	0.08...	0.09...	-0.0...
19	韩国	0.0284	-0.03408	0.1062	-0.02404	-0.04606	-0.0249	-0.01154	0.05106	0.0...	0.0...	-0.0...	0.06...	0.1056	0.00...
20	家用	0.09303	0.004674	0.151	-0.08795	0.03799	0.1286	0.1244	-0.1209	0.0...	0.1...	0.07...	0.1694	0.2598	0.1493
21	g	0.06279	0.01393	0.2534	-0.01994	0.03998	0.3231	0.07817	-0.07714	-0.0...	0.1...	0.06...	0.1422	0.1651	0.03...
22	男	0.06893	0.009893	0.1051	0.0005736	-0.02107	-0.1202	-0.1323	0.1462	-0.0...	-0.0...	-0.1...	0.09...	-0.0...	0.0156

5.词向量聚类

现在已经产生了词向量，接下来只需要计算出哪些词的向量距离比较近，就可以实现按照意义将标签词归类。

这里采用kmeans算法来自动归类，聚类结果展示的是每个词属于哪个聚类簇：

word	cluster_index
家用	83
g	83
男	79
套装	94
保暖	98
加绒	98
儿童	79
潮	90
正品	87

结果验证

最后通过SQL组件，在聚类簇中随意挑选一个类别出来，检验下是否将同一类别的标签进行了自动归类，这里

```
6 select * from ${t1} where  
cluster_index=10
```

选用第10组聚类簇。

看一下第10组的结果：


word ▲	cluster_index ▲
日本进口	10
俄罗斯	10
雨	10
坚果	10
台湾	10
韩国进口	10
男士内裤	10
记	10
云南	10
螺	10
油	10
新疆特产	10

通过结果中的“日本”、“俄罗斯”、“韩国”、“云南”、“新疆”、“台湾”等词可以发现系统自动将一些跟地理相关的标签进行了归类，但是里面混入了“男士内裤”、“坚果”等明显与类别不符合的标签，这个很有可能是因为训练样本数量不足所造成的，如果训练样本足够大，那么标签聚类结果会非常准确。

一、背景

随着互联网的发展，产生了大量的图片以及语音数据，如何对这部分非结构化数据行之有效的利用起来，一直是困扰数据挖掘工程师的一道难题。首先，解决非结构化数据常常要使用深度学习算法，上手门槛高。其次，对于这部分数据的处理，往往需要依赖GPU计算引擎，计算资源代价大。本文将介绍一种利用深度学习实现的图片识别案例，这种功能可以服用到图片的检黄、人脸识别、物体检测等各个领域。

下面尝试通过阿里云机器学习平台产品，利用深度学习框架Tensorflow，快速的搭架图像识别的预测模型，整个流程只需要半小时，就可以实现对下面这幅图片的识别，系统会返回结果“鸟”：




二、数据集介绍

本案例数据集及相关代码下载地址：


https://help.aliyun.com/document_detail/51800.html?spm=5176.doc50654.6.564.mS4bn9

使用CIFAR-10数据集，这份数据是一份对包含6万张像素为32*32的彩色图片，这6万张图片被分成10个类别，分别是飞机、汽车、鸟、毛、鹿、狗、青蛙、马、船、卡车。数据集截图：



数据源在使用过程中被拆分

成两个部分，其中5万张用于训练，1万张用于测试。其中5万张训练数据又被拆分成5个data_batch，1万张测试数据组成test_batch。最终数据源如图：



三、数据探索流程

下面我们一步一步讲解下如何将实验在阿里云机器学习平台跑通，首先需要开通阿里云机器学习产品的GPU使用权限，并且开通OSS，用于存储数据。机器学习：

<https://data.aliyun.com/product/learn?spm=a21gt.99266.416540.112.IOG7OUOSS>：

<https://www.aliyun.com/product/oss?spm=a2c0j.103967.416540.50.KkZyBu>

1.数据源准备

第一步，进入OSS对象存储，将本案例提供的相关数据和代码下载，并且解压缩，放到OSS的bucket对应的路

径下。首先建立OSS的bucket，然后我建立了aohai_test文件夹，并在这个目录下建立如下4个文件夹目录：

Folder Name	
	aohai_test/ Go back up a level
	check_point/
	cifar-10-batches-py/
	predict_code/
	train_code/

每个文件夹的作用如下：

check_point:用来存放实验生成的模型

cifar-10-batches-py：用来存放训练数据以及预测集数据，对应的是下载下来的数据源cifar-10-batcher-py文件和预测集bird_mount_bluebird.jpg文件

- predict_code:用来存放训练数据，也就是cifar_predict_pai.py
- train_code:用来存放cifar_pai.py

本案例数据集及相关代码下载地址：

https://help.aliyun.com/document_detail/51800.html?spm=5176.doc50654.6.564.mS4bn9

2.配置OSS访问授权


现在我们已经把数据和训练需要的代码放入OSS，下面要配置机器学习对OSS的访问，进入阿里云机器学习，在“设置”按钮的弹出页面，配置OSS的访问授权。如图：




3.模型训练

从左边的组件框中拖拽“读OSS Bucket”以及“Tensorflow”组件链接，并且在“Tensorflow”的配置项中进行相关设置。

- Python代码文件：OSS中的cifar_pai.py
- 数据源目录：OSS中的cifar-10-batches-py文件夹
- 输出目录：OSS中的check_point文件夹



点击运行，实验开始训练，可以针对底层的GPU资源灵活调节，除了界面端的设置，需要在代码中也有相应的支持，代码编写符合Tensorflow的多卡规范。



4.模型训练代码解析

这里针对cifar_pai.py文件中的关键代码讲解：（1）构建CNN图片训练模型

```
network = input_data(shape=[None, 32, 32, 3],
data_preprocessing=img_prep,
data_augmentation=img_aug)
network = conv_2d(network, 32, 3, activation='relu')
network = max_pool_2d(network, 2)
network = conv_2d(network, 64, 3, activation='relu')
network = conv_2d(network, 64, 3, activation='relu')
network = max_pool_2d(network, 2)
network = fully_connected(network, 512, activation='relu')
network = dropout(network, 0.5)
network = fully_connected(network, 10, activation='softmax')
network = regression(network, optimizer='adam',
loss='categorical_crossentropy',
learning_rate=0.001)
```


（2）训练生成模型名为model的一系列文件，这些文件组成了TF的预测模型

```
model = tflearn.DNN(network, tensorboard_verbose=0)
model.fit(X, Y, n_epoch=100, shuffle=True, validation_set=(X_test, Y_test),
show_metric=True, batch_size=96, run_id='cifar10_cnn')
model_path = os.path.join(FLAGS.checkpointDir, "model.tfl")
```

```
print(model_path)
model.save(model_path)
```

5.查看训练过程中的日志

训练过程中，右键“Tensorflow”组件，点击查看日志。




点击打开logview连接，按照如下链路操作，打开ODPS Tasks下面的Algo Task，双击Tensorflow Task，点击StdOut，可以看到模型训练的日志被实时的打印出来：

```
Logview [Stdout]
[2K] Adam | epoch: 100 | loss: 0.26830 - acc: 0.9044 -- iter: 49248/50000
[A [ATraining Step: 52093 | total loss: [1m [32m0.27007 [0m [0m | time: 17.023s
[2K] Adam | epoch: 100 | loss: 0.27007 - acc: 0.9056 -- iter: 49344/50000
[A [ATraining Step: 52094 | total loss: [1m [32m0.27512 [0m [0m | time: 17.057s
[2K] Adam | epoch: 100 | loss: 0.27512 - acc: 0.9088 -- iter: 49440/50000
[A [ATraining Step: 52095 | total loss: [1m [32m0.27783 [0m [0m | time: 17.090s
[2K] Adam | epoch: 100 | loss: 0.27783 - acc: 0.9075 -- iter: 49536/50000
[A [ATraining Step: 52096 | total loss: [1m [32m0.27609 [0m [0m | time: 17.121s
[2K] Adam | epoch: 100 | loss: 0.27609 - acc: 0.9053 -- iter: 49632/50000
[A [ATraining Step: 52097 | total loss: [1m [32m0.27241 [0m [0m | time: 17.153s
[2K] Adam | epoch: 100 | loss: 0.27241 - acc: 0.9043 -- iter: 49728/50000
[A [ATraining Step: 52098 | total loss: [1m [32m0.26988 [0m [0m | time: 17.182s
[2K] Adam | epoch: 100 | loss: 0.26988 - acc: 0.9066 -- iter: 49824/50000
[A [ATraining Step: 52099 | total loss: [1m [32m0.26066 [0m [0m | time: 17.215s
[2K] Adam | epoch: 100 | loss: 0.26066 - acc: 0.9087 -- iter: 49920/50000
[A [ATraining Step: 52100 | total loss: [1m [32m0.24700 [0m [0m | time: 18.614s
[2K] Adam | epoch: 100 | loss: 0.24700 - acc: 0.9136 | val_loss: 0.80838 - val_acc: 0.8175 -- iter:
50000/50000
--
oss://pai-shanghai-test/aohai_test/check_point/model/model.tfl
```

随着实验的进行，会不断打出日志出来，对于关键的信息也可以利用print函数在代码中打印，结果会显示在这里。在本案例中，可以通过acc查看模型训练的准确度。

5.结果预测

再拖拽一个“Tensorflow” 组件用于预测，



- Python代码文件：OSS中的cifar_predict_pai.py
- 数据源目录：OSS中的cifar-10-batches-py文件夹,用来读取bird_mount_bluebird.jpg文件
- 输出目录：读取OSS中的check_point文件夹下模型训练生成的model.tfl模型文件

预测的图片是存储在checkpoint文件夹下的图:



```
Logview [Stdout]
load data done
oss://pai-shanghai-test/aohai_test/check_point/model/model.tfl
[0.0, 0.0, 1.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0]
[0.0, 0.0, 1.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0]
This is a bird
```

结果见日志：

6.预测代码数据

部分预测代码解析：

```
predict_pic = os.path.join(FLAGS.buckets, "bird_bullocks_oriole.jpg")
img_obj = file_io.read_file_to_string(predict_pic)
file_io.write_string_to_file("bird_bullocks_oriole.jpg", img_obj)

img = scipy.ndimage.imread("bird_bullocks_oriole.jpg", mode="RGB")

# Scale it to 32x32
img = scipy.misc.imresize(img, (32, 32), interp="bicubic").astype(np.float32, casting='unsafe')

# Predict
prediction = model.predict([img])
print (prediction[0])
print (prediction[0])
#print (prediction[0].index(max(prediction[0])))
num=['airplane','automobile','bird','cat','deer','dog','frog','horse','ship','truck']
print ("This is a %s"%(num[prediction[0].index(max(prediction[0]))]))
```

首先读入图片 “bird_bullocks_oriole.jpg”，将图片调整为像素32*32的大小，然后带入model.predict预测

函数评分，最终会返回这张图片对应的十种分类

['airplane' , ' automobile' , ' bird' , ' cat' , ' deer' , ' dog' , ' frog' , ' horse' , ' ship' , ' truck']
的权重，选择权重最高的一项作为预测结果返回。注：因为模型训练存在随机性，所以不保证每次训练出的模型对于预测图片都可以返回准确结果，需要不断调试对应参数才能达到稳定效果，本实验只是简单案例。

【玩转数据】机器学习为您解密雾霾形成原因

一、背景



如果要人们评选当今最受关注话题的top10榜单，雾霾一定能够入选。如今走在北京街头，随处可见带着厚厚口罩的人在埋头前行，雾霾天气不光影响了人们的出行和娱乐，对于人们的健康也有很大危害。本文通过爬取并分析北京一年来的真实天气数据，挖掘出二氧化氮是跟雾霾天气（这里指的是PM2.5）相关性最强的污染物，从而为您揭秘形成雾霾的罪魁祸首。

这里我们是用阿里云机器学习平台来完成实验：<https://data.aliyun.com/product/learn>

登陆阿里云机器学习平台，即可在demo页选择实验并且亲手实现整个机器学习的预测分析，完全零门槛。

二、数据集介绍

数据源：采集了2016全年的北京天气指标。


采集的是从2016年1月1号以来每个小时的空气指标，。具体字段如下表：

字段名	含义	类型
time	日期，精确到天	string
hour	表示的是时间，第几小时的数据	string

pm2	pm2.5的指标	string
pm10	pm10的指标	string
so2	二氧化硫的指标	string
co	一氧化碳的指标	string
no2	二氧化氮的指标	string

三、数据探索流程


阿里云机器学习平台采用拖拉算法组件拼接实验的操作方式，先来看下整个实验流程：



我们把整个实验拆解成四个部分，分别是数据导入及预处理、统计分析、随机森林预测及分析、逻辑回归预测及分析。下面我们分别介绍一下这四个模块的逻辑。

1.数据导入及预处理

(1) 数据导入在“数据源”中选择“新建表”，可以把本地txt文件上传。



数据导入后查看：

time ▲	hour ▲	pm2 ▲	pm10 ▲	so2 ▲	co ▲	no2 ▲
2016...	2	85	123	18	1.8	72
2016...	8	114	127	25	2.3	81
2016...	11	123	140	27	2.5	83
2016...	14	134	150	30	2.6	86
2016...	17	150	168	32	2.8	92
2016...	20	166	191	34	3	97
2016...	23	179	207	35	3.2	101
2016...	1	190	222	37	3.4	104
2016...	10	225	249	39	3.8	107
2016...	19	244	287	41	4	113

（2）数据预处理通过类型转换把string型的数据转double。把pm2这一列作为目标列，数值超过200的情况作为重度雾霾天气打标为1，低于200标为0，实现的SQL语句如下。


```
select time,hour,(case when pm2>200 then 1 else 0 end),pm10,so2,co,no2 from ${t1};
```

（3）归一化归一化主要是去除量纲的作用，把不同指标的污染物单位统一。

time ▲	hour ▲	_c2 ▲	pm10 ▲	so2 ▲	co ▲	no2 ▲
20160101	2	0	0.24532224...	0.21917808219...	0.36956521739130427	0.43312101910828027
20160101	8	0	0.25363825...	0.31506849315...	0.4782608695652173	0.49044585987261147
20160101	11	0	0.28066528...	0.34246575342...	0.5217391304347825	0.5031847133757962
20160101	14	0	0.30145530...	0.38356164383...	0.5434782608695652	0.5222929936305732
20160101	17	0	0.33887733...	0.41095890410...	0.5869565217391303	0.5605095541401274
20160101	20	0	0.38669438...	0.43835616438...	0.6304347826086956	0.5923566878980892
20160101	23	0	0.41995841...	0.45205479452...	0.6739130434782609	0.6178343949044586
20160102	1	0	0.45114345...	0.47945205479...	0.7173913043478259	0.6369426751592356
20160102	10	1	0.50727650...	0.50684931506...	0.8043478260869563	0.6560509554140127
20160102	19	1	0.58627858...	0.53424657534...	0.8478260869565216	0.6942675159235668
20160102	22	1	0.68191268...	0.53424657534...	0.8913043478260869	0.7197452229299363
20160103	0	1	0.74428274...	0.53424657534...	0.8913043478260869	0.732484076433121
20160105	16	0	0.06860706...	0.02739726027...	0.06521739130434782	0.16560509554140126


2.统计分析

我们在统计分析的模块用了两个组件：（1）直方图通过直方图可以可视化的查看不同数据在不同区间下的分布。通过这组数据的可视化展现，我们可以了解到每一个字段数据的分布情况，以PM2.5为例，数值区间出现最多的是11.74~15.61，一共出现了430次。



（2）数据视图通过数据视图

可以查看不同指标的不同区间对于结果的影响。





以no2为例，在112.33~113.9这个区间产生了7个目标列为0的目标，产生了9个目标列为1的目标。也就是说当no2为

112.33~113.9区间的情况下，出现重度雾霾的天气的概率是非常大的。熵和基尼系数是表示这个特征区间对于目标值的影响，数值越大影响越大，这个是从信息量层面的影响。

3.随机森林预测及分析

本案其实是采用了两种不同的算法对于结果进行预测，我们先来看看随机森林这一分支。我们通过将数据集拆分，百分之八十的数据训练模型，百分之二十的数据预测。最终模型的呈现可以可视化的显示出来，在左边模型菜单下查看，随机森林是树状模型。



准确率： 我们看到AUC是0.99，也就是说如果我们有了本文用到的天气指标数据，就可以预测天气是否雾霾，而且准确率可以达到百分之九十以上。

4.逻辑回归预测及分析

再来看下逻辑回归这一分支的预测模型，逻辑回归是线性模型：


逻辑回归二分类

在输入数据为稀疏的时候，不显示 weight 全是 0 的特征

字段名 ▲	权重	
	1 ▲	0 ▲
pm10	18.32146628653672	-
so2	1.767062094833547	-
co	-0.2519492790928399	-
no2	10.95221282178011	-
常量	-16.66654139199668	0

模型预测准确率：

评估报告



逻辑回归的AUC为0.98，比用随机森林计算得到的结果略低一点。如果排除调参对于结果的影响因素，可以说明针对这个数据集，随机森林的训练效果会更好一点。

四、结果评估

上面介绍了如何通过搭建实验来搭建针对PM2.5的预测流程，准确率达到百分之九十以上。下面我们来分析一下哪种空气指标对于PM2.5影响最大，首先来看下逻辑回归的生成模型：

逻辑回归二分类



在输入数据为稀疏的时候，不显示 weight 全是 0 的特征

字段名 ▲	权重	
	1 ▲	0 ▲
pm10	18.32146628653672	-
so2	1.767062094833547	-
co	-0.2519492790928399	-
no2	10.95221282178011	-
常量	-16.66654139199668	0

因为经过归一化计算的逻辑回归算法有这样的特点，模型系数越大表示对于结果的影响越大，系数符号为正号表示正相关，负号表示负相关。我们看一下正号系数里pm10和no2最大。pm10和pm2只是颗粒尺寸大小不同，是一个包含关系，这里不考虑。剩下的no2(二氧化氮)对于pm2.5的影响最大。我们只要查阅一下相关文档，了解下哪些因素会造成no2的大量排放即可找出影响pm2.5的主要因素。下面网上是找到的关于no2排放的论述,文中说明了no2主要来自汽车尾气。no2来源文章

五、其它

参与讨论：云栖社区公众号

免费体验：阿里云数加机器学习平台