大数据分析的一条入门途径

——以拍拍贷风控模型预测为例

范方达

Kesci“魔镜杯”风控算法大赛 涌泉队

2016.4

出发点

- 大数据是更多人可以理解的
- 大数据的方法也是更多人可以理解的
- 大数据没有祖传秘方——不要把曾经初学的我们拦在外面
- 这并不是唯一一个正确答案，而是恩典在面对每一个小小的困难中的累积

目的

- 为数据分析初学者提供一点点数据分析的思路
- 为Python初学者提供一点点Python处理数据的技巧
- 为机器学习过程遇到的难题提供一点点解决方案

大纲

大纲

数据与目标

“魔镜杯”风控算法大赛复赛数据

- 样本
  - 训练样本：初赛训练集+初赛预测集+复赛训练集 （8万）
  - 预测样本：复赛预测集 （1万）
- 自变量
  - 主表（226个）
  - 登录信息（4个，但每个index有多条）
  - 用户更新信息（3个，但每个index有多条）
- 预测变量Y: 每个index的6个月内贷款逾期情况（0-1）
- 优化目标：预测变量Y在预测样本的AUC得分

代码平台

Python 3.5

- Packages：
  - 代码笔记本： jupyter
  - 基础: numpy, scipy, pandas, matplotlib, time, re
  - 模型: sklearn, xgboost, keras (theano), hyperopt
- Windows下建议Anaconda，包含科学计算的众多常用包

流程预览

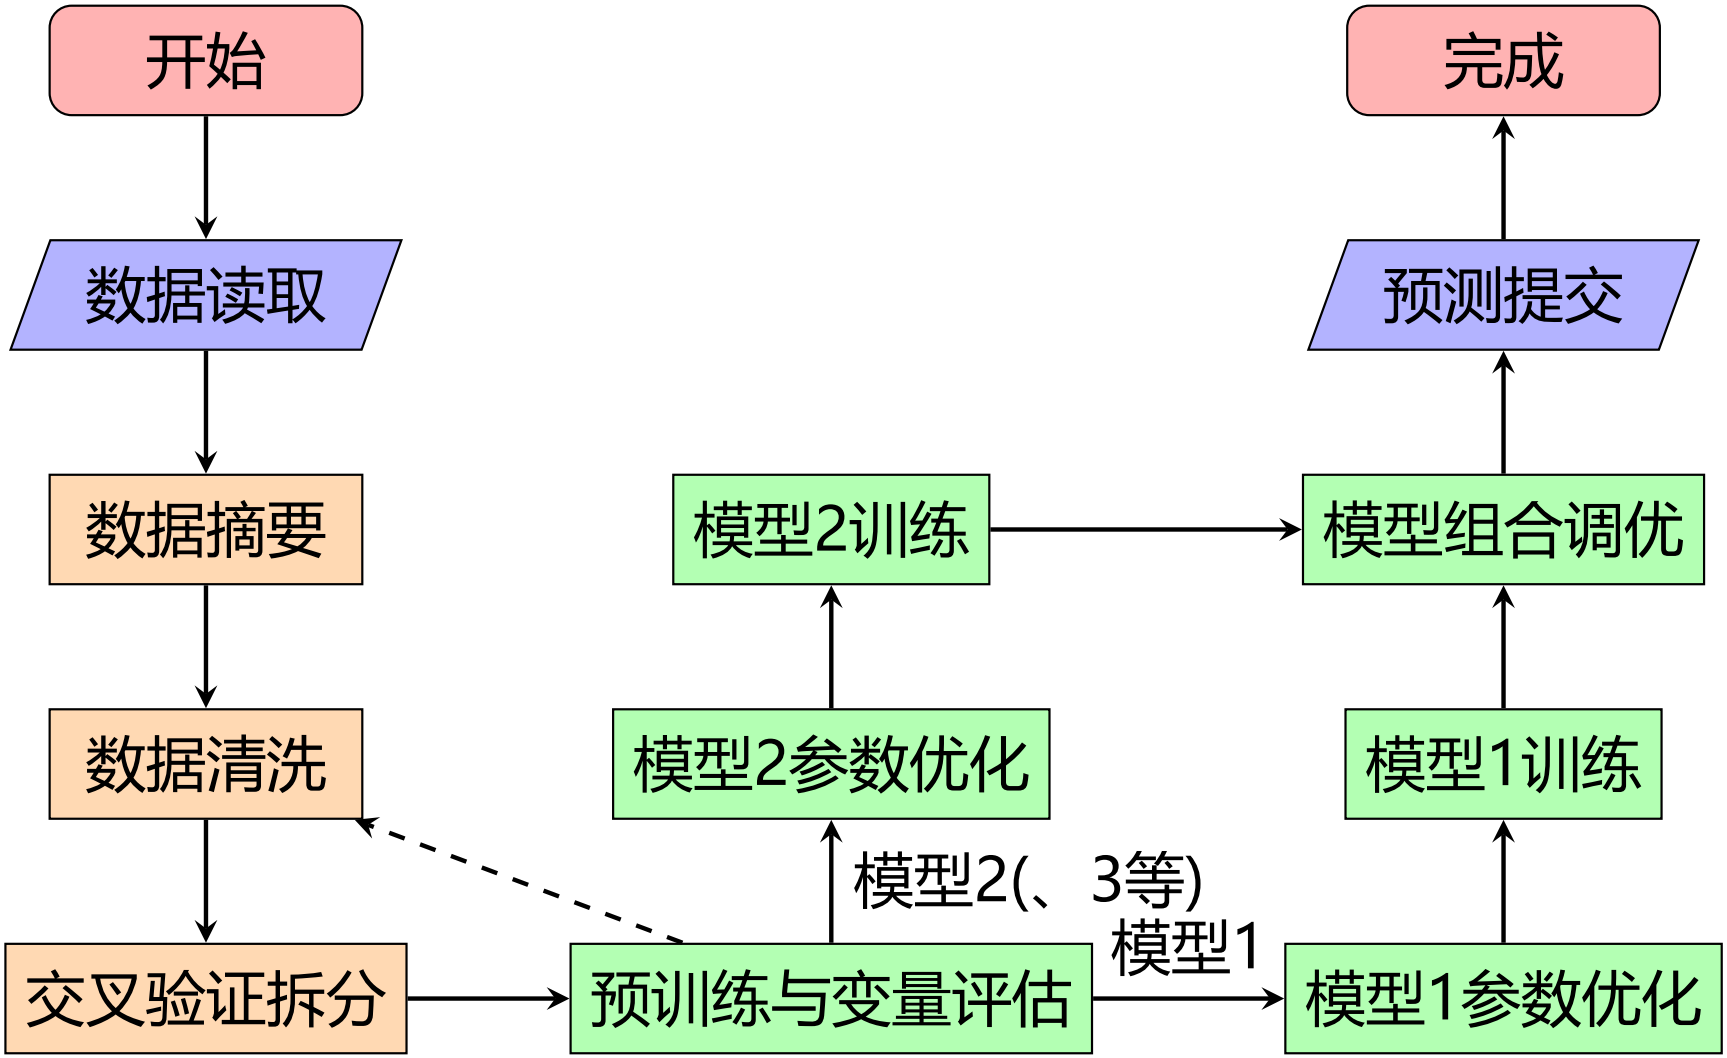
开始
数据读取
数据摘要
数据清洗
交叉验证拆分
预训练与变量评估
模型2(、3等)
模型1
模型2参数优化
模型2训练
模型组合调优
模型1训练
模型1参数优化
预测提交
完成

大纲

数据读取

- Q: 数据集有一些不同的文件，怎样合成一个数据呢？
- A: 首先我们可以根据数据类型为它们重命名来分门别类
  - 项目名(PPD)可以做前缀，区分项目时一目了然
  - 主表(da)、历史记录(dah)、辅助(daa)、初赛预测列(day)
  - 训练集(t)、预测集(v)
  - 重复的可以通过字段和数字序号添加后缀标识
- 用pandas包批量读数据
  - pd.concat + map + pd.read_csv + 文件名的list
  - 记得读数据时将文件中表示空值的一些符号标记为空值
  - 通过主表DataFrame的fillna把初赛预测列填充好

历史记录处理

- Q: 历史记录的两个表LogInfo和UserUpdate怎样使用呢？
- A: 通常地说，历史记录与主表建立联系的难点在于：
  - 每个index对应多条记录
  - 每条记录分属不同的事件类别
  - 各条记录时间有先后顺序
- 风控中，登录/信息上传的起始时间和频率对衡量借款人的行为或许较重要。进一步，我们也可统计每类事件的频率
- 我们对此有解法：对历史记录按index来分组汇总（比如总频率和起始时间），使每个index记录唯一，就可以与主表接合了
  - 针对时间性问题：同时按index和时间分组计数/去重/...等
  - 针对类别性问题：同时按index和类别分组计数/去重/...等

数据批处理实现

这两个批量整理数据的组合非常实用，也是我们后续进行数据摘要与清洗的主力

- pd.concat + map + (function) + (list)
  - 逐行/逐列批量应用函数
  - axis = 0，按行：批量整理样本等
  - axis = 1，按列：批量整理变量等
- pd.DataFrame: groupby + count/first/aggregate/...
  - 将行/列分组，逐组汇总数据
  - axis = 0，按行：整理分组样本等（如历史记录）
  - axis = 1，按列：整理系列变量等（如不同类别/时期的第三方信息变量）

大纲

数据摘要

- Q: 当我整理好数据集之后，我要做什么呢？
- A: 首先我们要从大局出发，简化并理解数据特征。
  具体地，可以通过循环/pd.concat+map对各变量处理汇总成一个表格。各行是变量名（原数据的每一列），而各列的内容有：
  - 变量是什么类型
  - 变量的空值/非空值数量
  - 变量出现频数前5大的值与数量，和其他值的数量（尾巴）
  - 数值变量的统计量：均值、方差、四分位数、最值

数据摘要展示：摘要前

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC	AD	AE	AF	AG	AH	AI	AJ	AK	AL	AM	AN	AO	AP	AQ	AR	AS	AT	AU	AV	AW	AX	AY	AZ	BA	BB	BC	BD	BE	BF	BG	BH	BI	BJ	BI
1	Id	Usi	Usi	Usi	Usi	We	We	We	We	We	We	We	We	We	We	We	We	We	We	We	We	We	We	We	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Usi	Ed	Ed	Ed	Ed	Ed	Ed	Ed	We	We	We	We	We	We	We	We	We	We	We	We	We	We	We
2	#	1	深	4	深圳	1		1	1	1	14	0	0	0	0	0	0	6	6	0	6	2	2	2	广	深	中	0				2	2	1	1	29	四	南	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
3	#	1	温	4	温州	0		1	1	1	14	0	0	0	0	0	0	0	0	0	7	7	0	2	2	浙	温	中	1	0	0	1	3	3	2	2	28	福	不	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
4	#	1	宜	3	宜昌	0		2	2	2	9	3	0	0	0	0	0	0	0	0	3	4	2	2	2	湖	宜	中	0	0	0	1	4	4	2	1	32	湖	宜	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
5	#	4	南	1	南平						2	0	0	0	0	0	0	0	0	0	2	0	2	2	福	南	中	0	0	0	1	2	2	1	1	33	江	不	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
6	#	5	辽	1	辽阳	0		1	1	1	3	0	0	0	0	0	0	0	0	0	3	0	2	2	辽	辽	中	0				3	3	1	1	43	辽	锦	0	D	D	D	0	E	E	E	0	E	E	E	I		D	0	0	0	0	0	0	0	0
7	#	1	吴	5	银川	0		2	2	2	4	0	0	0	0	0	0	0	0	1	1	2	0	2	2	不	不	不	0				4	4	2	1	24	山	不	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	0	0
8	#	1	绵	3	赤峰	0		13	1	13	15	0	0	0	0	0	0	0	0	2	2	10	1	2	2	内	包	中	1	1	0	0	2	2	1	1	33	内	赤	0	D	D	D	0	E	E	E	0	E	E	E	I	I4	D	0	0	0	0	0	0	1	0
9	#	4	东	5	东莞	0		12	6	12	8	0	0	0	0	0	0	0	0	2	1	3	2	2	2	广	广	中	1				5	5	1	1	29	湖	荆	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	1	0	0	0
10	#	1	赤	6	赤峰	0		10	6	10	19	0	0	0	0	0	1	0	1	9	7	2	1	2	内	赤	中	0				3	3	1	1	29	内	赤	1	未	M	内	1	AM	毕	T	0	E	E	E	I	C1	D	0	1	0	0	1	1	0	1
11	#	3	武	5	鄂州	0		1	1	1	6	0	0	0	0	0	0	0	0	1	3	2	1	1	湖	鄂	中	0				4	4	1	1	34	湖	鄂	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	0	0
12	#	5	武	5	武汉	0		3	2	3	11	0	0	0	0	0	0	0	0	2	9	0	1	1	湖	武	中	0	0	1	0	2	2	1	2	28	湖	武	0	D	D	D	0	E	E	E	0	E	E	E	I	I3	D	1	0	0	1	1	0	0	1
13	#	5	长	5	长沙	1		1	1	1	4	0	0	0	0	0	0	0	0	0	1	3	0	1	1	湖	长	中	0				3	3	1	1	24	湖	湘	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
14	#	3	漳	3	漳州	1		11	3	11	31	0	0	0	0	0	0	0	0	2	3	25	1	2	2	福	漳	中	0				6	4	3	1	27	福	漳	0	D	D	D	0	E	E	E	0	E	E	E	I	I3	D	0	0	0	0	3	0	1	1
15	#	3	牡	6	牡丹江	0		1	1	1	4	0	0	0	0	0	0	0	0	0	4	0	1	1	黑	牡	中	0				3	3	1	1	31	黑	牡	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
16	#	1	太	3	太原	0		3	1	3	9	0	0	0	0	0	0	0	0	1	0	6	2	2	2	山	太	中	0				5	5	3	1	23	山	太	1	未	G	山	0	E	E	E	0	E	E	E	I		D	0	0	0	0	0	0	1	0
17	#	1	北	6	北京	0		2	2	1	7	0	0	0	0	0	0	0	0	2	0	0	7	0	2	2	北	北	中	1	0	1	1	2	2	2	1	38	内	不	0	D	D	D	0	E	E	E	0	E	E	E	I	I3	D	0	0	0	0	0	0	1	0
18	#	1	成	3	忻州	0		4	3	4	9	0	0	0	0	0	0	0	0	1	2	3	3	2	2	山	忻	中	0	0	0	1	2	4	2	1	26	山	不	0	D	D	D	0	E	E	E	0	E	E	E	E	U	C	0	0	0	0	1	0	1	1
19	#	1	三	4	三明	0		4	2	4	18	0	0	0	0	0	0	0	8	0	10	4	4	2	2	福	三	中	1				3	3	1	1	32	福	三	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
20	#	1	临	6	临沂	0		1	1	1	3	0	0	0	0	0	0	0	0	0	3	0	2	2	山	临	中	0				4	4	1	1	29	山	临	0	D	D	D	0	E	E	E	0	E	E	E	I	C2	D	0	0	0	0	0	0	0	0
21	#	4	临	6	临沂	0		2	2	2	3	0	0	0	0	0	0	0	0	0	1	2	2	2	山	临	中	1	0	1	0	3	3	1	1	37	辽	丹	0	D	D	D	0	E	E	E	0	E	E	E	I	C1	D	0	1	0	0	0	0	1	0
22	#	1	福	5	福州	0		3	2	3	20	0	0	0	0	0	0	0	9	6	4	4	6	1	2	福	福	中	1				5	5	1	1	30	四	绵	0	D	D	D	0	E	E	E	0	E	E	E	I	C2	D	0	0	0	0	1	0	1	0
23	#	4	泰	4	泰州	0		3	2	3	8	0	0	0	0	0	0	0	3	0	2	0	6	2	2	江	泰	中	0	0	0	1	4	4	2	1	34	江	扬	0	D	D	D	0	E	E	E	0	E	E	E	F	I5	C	0	0	0	0	0	0	1	0
24	#	5	成	4	大同	0		8	8	8	46	24	0	0	0	0	0	0	0	6	29	11	1	1	山	大	中	1				5	3	1	1	24	山	大	0	D	D	D	0	E	E	E	0	E	E	E	D	I5	A	0	1	0	0	0	2	1	0
25	#	4	上	5	上海	1		1	1	1	0	0	0	0	0	0	0	0	0	0	0	1	1	1	不	不	不	0	0	0	1	3	3	2	1	29	福	南	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
26	#	1	红	5	红河哈	0		1	1	1	8	0	0	0	0	0	0	0	0	1	4	3	2	2	云	红	中	0				4	4	2	1	26	云	红	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	3	0	0	0	0	1	0
27	#	4	南	4	南平	0		2	1	2	7	0	0	0	0	0	0	0	0	2	0	3	2	1	1	福	南	中	0	0	0	1	4	4	2	1	23	福	三	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
28	#	1	郴	5	郴州	0		9	5	9	32	0	0	0	0	0	0	0	15	12	6	10	4	1	1	湖	郴	中	0				3	3	1	1	26	湖	郴	0	D	D	D	0	E	E	E	0	E	E	E	I	I5	D	0	0	0	0	0	0	1	0
29	#	3	常	4	常州	0		2	2	2	11	3	0	0	0	0	0	0	0	4	0	5	2	1	1	江	常	中	1				2	2	6	1	30	江	常	0	D	D	D	0	E	E	E	0	E	E	E	I	F1	D	0	0	0	0	0	0	2	0

PPD_dat_1

数据摘要展示：摘要后

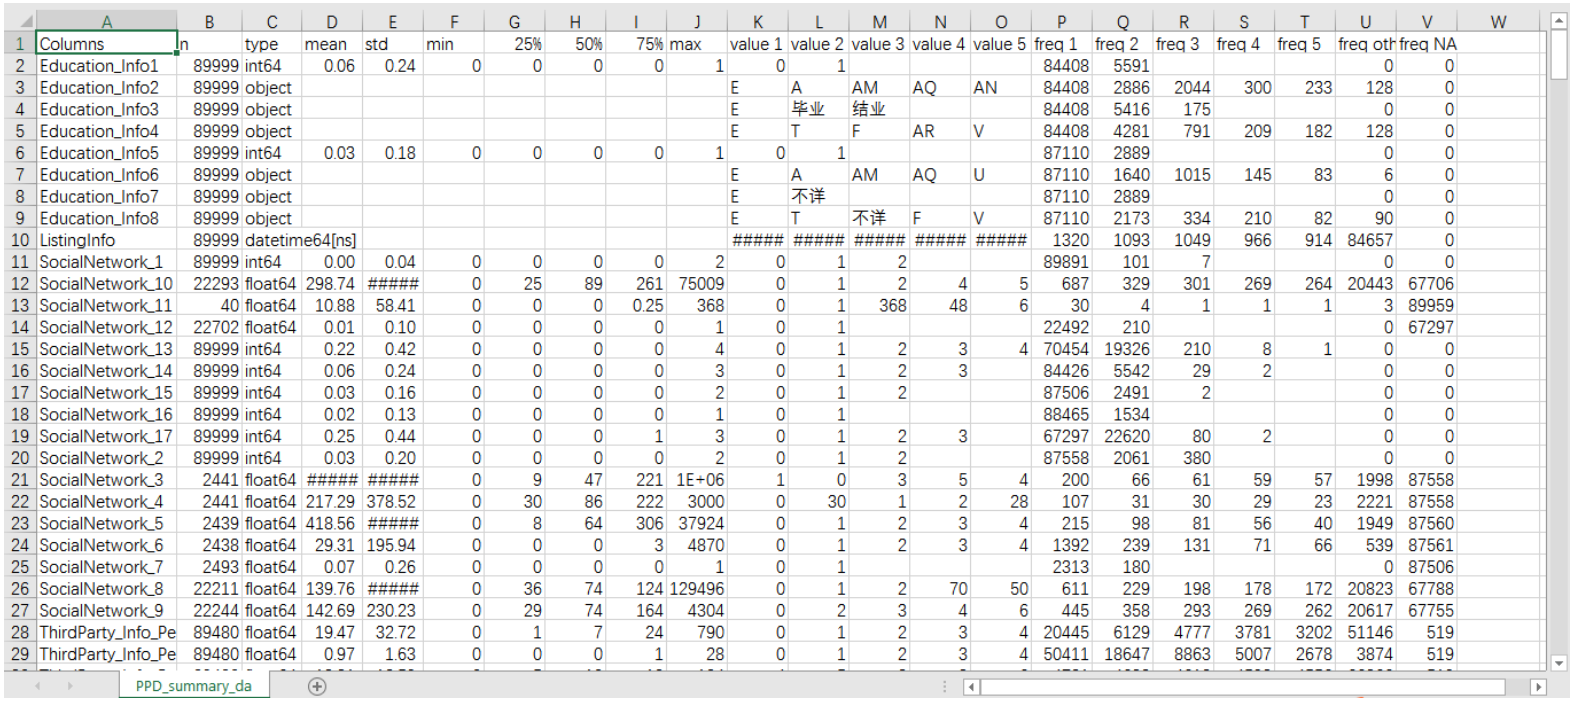

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W
1	Columns	n	type	mean	std	min	25%	50%	75%	max	value 1	value 2	value 3	value 4	value 5	freq 1	freq 2	freq 3	freq 4	freq 5	freq oth	freq NA	
2	Education_Info1	89999	int64	0.06	0.24	0	0	0	0	1	0	1				84408	5591				0	0	
3	Education_Info2	89999	object								E	A	AM	AQ	AN	84408	2886	2044	300	233	128	0	
4	Education_Info3	89999	object								E	毕业	结业			84408	5416	175			0	0	
5	Education_Info4	89999	object								E	T	F	AR	V	84408	4281	791	209	182	128	0	
6	Education_Info5	89999	int64	0.03	0.18	0	0	0	0	1	0	1				87110	2889				0	0	
7	Education_Info6	89999	object								E	A	AM	AQ	U	87110	1640	1015	145	83	6	0	
8	Education_Info7	89999	object								E	不详				87110	2889				0	0	
9	Education_Info8	89999	object								E	T	不详	F	V	87110	2173	334	210	82	90	0	
10	ListingInfo	89999	datetime64[ns]								#####	#####	#####	#####	#####	1320	1093	1049	966	914	84657	0	
11	SocialNetwork_1	89999	int64	0.00	0.04	0	0	0	0	2	0	1	2			89891	101	7			0	0	
12	SocialNetwork_10	22293	float64	298.74	#####	0	25	89	261	75009	0	1	2	4	5	687	329	301	269	264	20443	67706	
13	SocialNetwork_11	40	float64	10.88	58.41	0	0	0	0.25	368	0	1	368	48	6	30	4	1	1	1	3	89959	
14	SocialNetwork_12	22702	float64	0.01	0.10	0	0	0	0	1	0	1				22492	210				0	67297	
15	SocialNetwork_13	89999	int64	0.22	0.42	0	0	0	0	4	0	1	2	3	4	70454	19326	210	8	1	0	0	
16	SocialNetwork_14	89999	int64	0.06	0.24	0	0	0	0	3	0	1	2	3		84426	5542	29	2		0	0	
17	SocialNetwork_15	89999	int64	0.03	0.16	0	0	0	0	2	0	1	2			87506	2491	2			0	0	
18	SocialNetwork_16	89999	int64	0.02	0.13	0	0	0	0	1	0	1				88465	1534				0	0	
19	SocialNetwork_17	89999	int64	0.25	0.44	0	0	0	1	3	0	1	2	3		67297	22620	80	2		0	0	
20	SocialNetwork_2	89999	int64	0.03	0.20	0	0	0	0	2	0	1	2			87558	2061	380			0	0	
21	SocialNetwork_3	2441	float64	#####	#####	0	9	47	221	1E+06	1	0	3	5	4	200	66	61	59	57	1998	87558	
22	SocialNetwork_4	2441	float64	217.29	378.52	0	30	86	222	3000	0	30	1	2	28	107	31	30	29	23	2221	87558	
23	SocialNetwork_5	2439	float64	418.56	#####	0	8	64	306	37924	0	1	2	3	4	215	98	81	56	40	1949	87560	
24	SocialNetwork_6	2438	float64	29.31	195.94	0	0	0	3	4870	0	1	2	3	4	1392	239	131	71	66	539	87561	
25	SocialNetwork_7	2493	float64	0.07	0.26	0	0	0	0	1	0	1				2313	180				0	87506	
26	SocialNetwork_8	22211	float64	139.76	#####	0	36	74	124	129496	0	1	2	70	50	611	229	198	178	172	20823	67788	
27	SocialNetwork_9	22244	float64	142.69	230.23	0	29	74	164	4304	0	2	3	4	6	445	358	293	269	262	20617	67755	
28	ThirdParty_Info_Pe	89480	float64	19.47	32.72	0	1	7	24	790	0	1	2	3	4	20445	6129	4777	3781	3202	51146	519	
29	ThirdParty_Info_Pe	89480	float64	0.97	1.63	0	0	0	1	28	0	1	2	3	4	50411	18647	8863	5007	2678	3874	519	

PPD_summary_da

这样，我们可以通过表格的信息来对变量特性一目了然，并能帮助我们进行后续清洗工作。

数据清洗：目的

- Q: 为什么我们要进行数据清洗？
- A: 模型向往的是分布良好的数值，数据却有着骨感的现实
  - 空缺、类别（字符串）……——模型陷进了Bug中
  - 稀疏性、共线性、极端值……——模型迷失在数学中
  - 时间、地理名称……——模型在人类知识面前踌躇不进
- 我们要为模型铺平数据的道路，使模型能在其上飞驰
- 整个数据分析流程的重中之重

数据清洗：思路

- Q: 这么多变量，真的需要我一个一个看来清洗吗？
- A: 不必的，我们要搭建通用的5步法先后处理掉清洗工作：
  1. 数值变量保留，**非数值变量**全部转为数值变量：
     - **有额外信息的非数值变量**可以转化为根据先验知识得到的数值中（比如时间转为年、月、日、星期、以及相对天数等，地名转为经纬度和城市等级，定序变量保留序数等）
     - **其余非数值变量**全部用OneHotEncoder转为0-1哑变量
  2. 对**一系列相似变量**可取求和、中位数、方差、最值、空值数等统计量取代原变量（比如几个省份、城市、不同时期的第三方信息变量等）。选取统计量重精不重多，尽量互相独立
  3. 删掉空值/同一值占绝大比例(比如99.9%)的**稀疏变量**
  4. 以相关矩阵的下三角阵中包含接近± 1来筛选删除**共线变量**
  5. 用中位数（或平均数）填充**空值**，再进行标准化

数据清洗：实践

- Q: 什么时候该选用中位数而不是平均数填充空值呢？
- A: 数据分布不对称时，中位数比平均数更能保持排序关系
- Q: 我该怎样批量清洗这些变量呢？
- A: 我们可继续让批量转换pd.concat+map组合和分组汇总groupby+aggregate组合大显身手，而我们只需做几个对变量执行不同清洗功能的函数，然后把各变量按类别分类扔给它们
- 当我们完成了清洗的工作后，即将踏入建模阶段

大纲

Logistic Regression

- Q: 如果我刚入门机器学习，应该从什么模型开始？
- A: Logistic Regression：最简洁、快速、稳健的做法，可解释性强，适于工业界
- 但由于比赛以精度为标准，由于Logistic Regression对变量关系的线性限制，难以达到精度最优
- 但是我们在建模时可以充分发挥它的特性：
  - 通过增加L2罚函数减少过拟合
  - 作为基准，对数据清洗效果和模型表现进行快速评估
  - 与结构不同的模型加权组合预测，补充原模型精度和稳健性

XGBoost（梯度强化树）

- Q: 如果我对机器学习已经有所了解，打算以精度为目标，用什么模型效果好？
- A: 考虑这是一个非线性的分类问题，变量成分较多元，样本和变量间无固定模式关联（图像、语音、时间序列等）。如果以精度为目标，综合考虑稳健性、速度、通用性等因素可以首选XGBoost
- Q: XGBoost的原理是什么？有哪些重要参数？
- A: XGBoost一种梯度强化树(Gradient Boosting Trees)。好比用大石头雕刻人像，每棵决策树都凿掉一些石头（残差），然后对剩下的石头继续雕刻，直到雕出人形
  - 步长(eta)雕刀：大斧子 vs. 小凿子
  - 变量抽样(colsample_bylevel)匠师：项羽 vs. 刘邦
  - 深度(depth)刀法：平推 vs. 直钻

Keras（神经网络）

- Q: 如果我对XGBoost的精度仍不满足，想达到更好的预测效果，该如何做？
- A: 可以尝试神经网络Keras，并把XGBoost与多种模型组合
- XGBoost的出发点是各变量完全独立，而从决策树的二分关联叠加向真实关联趋近；而神经网络的出发点是各变量充满复杂的非线性关联，而不断去优化网络权重向真实关联趋近。两种模型结构具有较高的互补性
- 由于神经网络内部结构复杂，寻找最优解困难，除了合理搭建网络结构、优化参数之外，对数据建议把X各变量**标准化为正态分布**。
  - 目的：去除影响神经网络训练的有偏分布和极端值
  - 实现方法：可以通过rank和正态分布的百分位函数复合
  - 在本数据集能明显提高神经网络和LR的效果

模型对比

- 精度以相同的10-folds交叉验证为准
- 训练样本8万，变量经清洗后共389个，正态分布标准化
- 计算平台：Intel Core i5 4300U 双核 2.5 GHz, 8 GB 内存

模型	LR	XGBoost	Keras
类型	逻辑回归	梯度强化树	神经网络
平均精度(AUC)	0.775	**0.787**	0.771
最差精度(AUC)	0.759	**0.768**	0.753
单模型时间(s)	**8**	350	400
调参个数	**2**	8	10+
可解释性	**好**	中	水平不行
支持分布式	**是**	**是**	否

大纲

交叉验证与模型训练

- Q: 为什么要用交叉验证？怎样用？
- A: 较比用单训练预测集建模，交叉验证的优势主要有：
  - 更准确地估计模型的预测精度
  - 可以预估模型预测效果的区间范围
  - 减少模型优化过程中对单验证集的过拟合情况
- 以10-folds为例做交叉验证：
  1. 把数据按列分成X和Y（预测目标列为Y，其他的列为X）
  2. 把样本行的index随机拆成10份保存起来
  3. 每次取1份index作验证集，另外9份index粘起来作训练集，以取的X和Y的训练和验证集训练模型，把模型保存起来
  4. 依次取10组不同的index，得到一组10个模型
  5. 预测时用10个模型预测结果取平均

模型评估

- Q: 模型训练的过程中，我们如何评价模型的效果？
- A: 我们可以从验证集分数和训练时间两个角度予以评价。其中交叉验证的验证集分数包含着模型效果的更多信息：
  - 均值：反映模型精度
  - 标准差/置信区间：反映模型稳健性，预估模型预测效果在不同数据集上的波动范围。在独立正态假设下，用模型均值预测不同数据集（比如排行榜和非公开的验证集）的标准差大约是验证分数标准差的$\frac{1}{\sqrt{K}}$（K-folds交叉验证）
  - 箱线图(box-plot)：可视化地展现验证分数的分布规律并发现异常情况

变量评估

- Q：我们该如何了解Y受哪些变量影响呢？
- A：可以用XGBoost判断变量重要性，再用LR看影响方向
  - 线性影响：Logistic Regression的系数来评估
    - 正负号表示对Y值的正影响或负影响
    - （变量X标准化后）系数绝对值越高影响越大
    - 受共线性影响大，可能使变量与Y虚假相关
  - 非线性影响：XGBoost各变量的相对频率来评估
    - 可用$\frac{\text{fscore}}{\text{Mean(fscore)}}$计算相对频率，fscore为XGB模型get_fscore得到的树分支挑选各变量的频数
    - 相对频率大于1的为在模型中明显有效的变量，远小于1则为较不重要的变量
    - 受共线性影响小，稳健性高

变量评估展示

如图为XGB变量相对频率按组汇总，可据此改进我们的

- 数据收集：增加对重要变量的收集
- 变量处理：针对重要变量在模型清洗阶段进一步转换组合

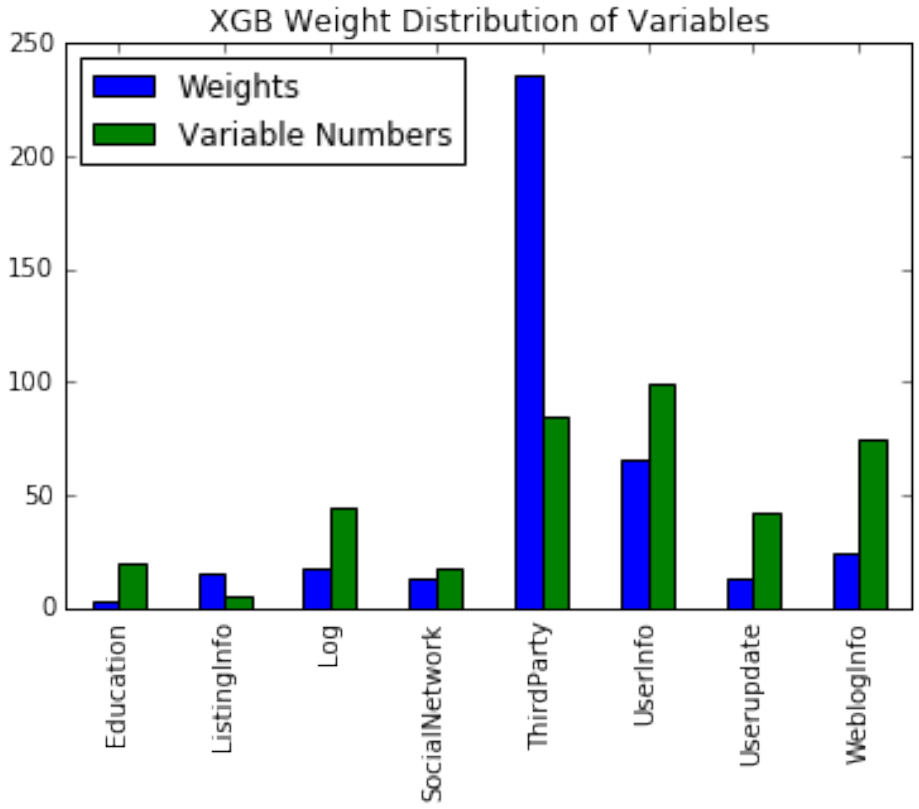

参数优化

- Q: 如何进行参数优化？怎么选取初始值？
- A: 模型调参是非常考验耐心和时间的过程
  1. 在调参前，首先要理解模型和参数的含义，这步非常关键
  2. 先用单数据集，从默认值开始，手工逐个调参熟悉模型，小范围用等差数列，大范围用等比数列，确定合理参数范围
  3. 确定大致范围后，可以用交叉验证+自动搜索来得到最优参数，如Python的HyperOpt包
- 如果模型训练是以10-folds验证的话，我们可以用5-folds交叉验证来自动搜索寻找最优参数
  - 节约调参时间
  - 数据集不同，减少对交叉验证结果的过拟合
- 在找到最优参数后，我们重新在原交叉验证集上用最优参数训练模型，至此模型训练阶段结束

大纲

模型组合

当训练优化好各组交叉验证模型后，就可将各组模型**加权平均**预测了，比如我们这里使用XGBoost，Keras和LR三组模型加权平均，并使用HyperOpt取得最优加权权重

- Q: 为什么要使用模型加权平均而不是最优模型预测？
- A: 数学上，如果一个无偏模型的预测方差为V_1，当我们加入另一个无偏而完全独立的模型，该模型预测方差为V_2，当我们对两模型的预测结果加权平均取最优解时，预测方差会变成原V_1的$\frac{V_2}{V_1+V_2}$倍
- 当然因为实际数据集和模型结构所限，真实的模型往往是有偏的，而只有一小部分相互独立，因此改进效果并没有理论上那样明显，但至少是一种比较稳健的方法
- 预测提交时，我们先对三组模型的交叉验证预测Y分别算术平均，再把这三个Y照权重加权平均，就可以提交了

效果展示

- 不同模型组合在同一10-folds交叉验证集上的得分分布
- 训练样本8万，变量经清洗后共389个，正态分布标准化
- 最优权重：XGB+LR=90:10，XGB+Keras+LR=75:20:5
  - Keras虽然预测精度较低，但结构互补进一步改善模型效果

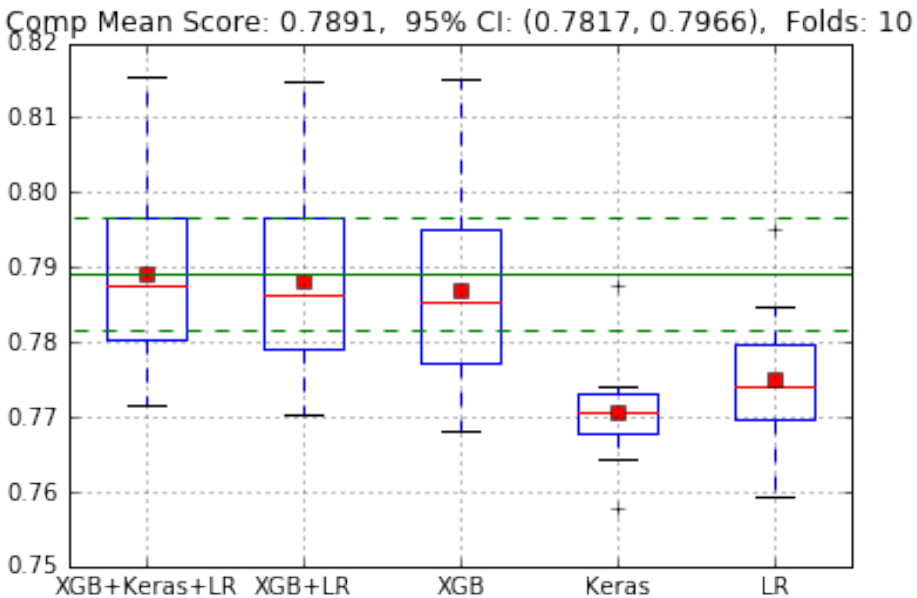

预测反馈

- Q: 为什么排行榜上的结果要比交叉验证的结果要好/差？
- A: 通常来说，预测的结果稍可能比交叉验证略好，原因是在不同数据集的交叉验证模型取平均形成部分互补减小误差
- 当然，因为预测集数据分布有随机性，预测效果的区间大致可以通过交叉验证的均值$\pm \frac{2}{\sqrt{K}}$标准差来估算（K-folds）
- 我们也要在全程中注意避免过拟合，包括：
  - 避免将Y的真值/预测信息在数据清洗或建模时引入到X中
  - 模型优化时采用另外划分的交叉验证集
  - 尽量能说清所做每一步处理的必要性和通用性
  - 注意：反复尝试变量组合提高验证集分数时，可能造成过拟合

大纲

流程回顾

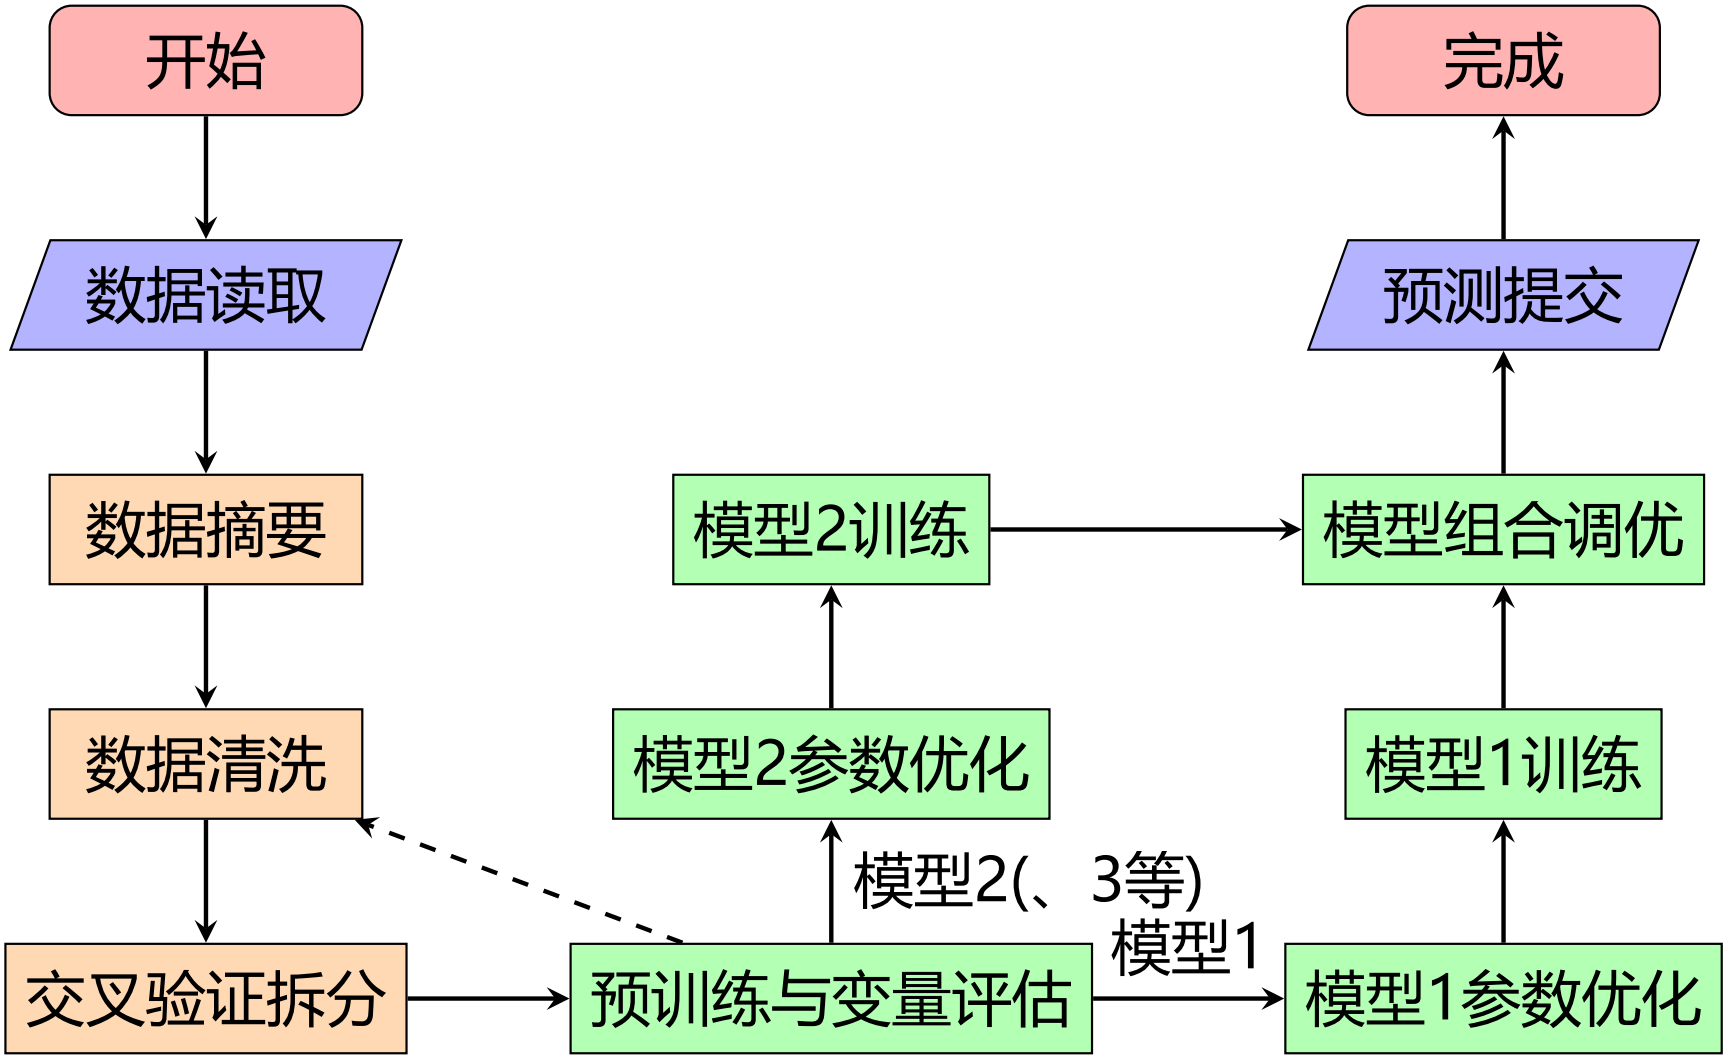
开始
数据读取
数据摘要
数据清洗
交叉验证拆分
预训练与变量评估
模型2(、3等)
模型1
模型2训练
模型2参数优化
模型1训练
模型1参数优化
模型组合调优
预测提交
完成

流程思想要点

- 为数据建模逐步搭建通用的函数（清洗、拆分、训练、优化等），将整个流程尽量自动化、可重复、可移植
- 注意对数据建模的整个过程进行评估（时间、复杂性、过拟合等），减少不必要的中间环节
- 清洗数据时，构造的人工变量要少而精，在相互独立和完备覆盖之间取得平衡，从而为模型增加有效信息帮助预测

改进潜力

- 当我们完成所有数据建模的必要工作时，在有需要而且有资源足够的前提下，可以在当前预测精度上进一步改进
  - 数据清洗：对预测Y较重要的变量之间，可尝试不同种类的组合变换（四则运算、各种分布变换、系列变量的各类统计量等），增加模型可以发掘的有效信息
  - 模型选择：可引入更多种类的模型，如随机森林，不同结构（层数、激活函数等）的神经网络等，改善模型互补性
  - 参数优化：减小梯度模型步长，在更多参数维度中搜索最优
- 但是
  - 会继续指数级增加所需时间、精力、计算量
  - 精度提升和算法的通用性改进会明显减少
  - 可能陷入为改进而改进的循环中
  - 直到机器学习界的AlphaGo取代人工劳作的数据分析师

“因为认识耶和华的知识要充满遍地，好像水充满洋海一般。”(以赛亚书11:9)

局限与反思

- 同时，我们目前所做的数据模型是很有限的：
  - 数据的预测局限：当试图穷尽数据处理、模型、调参等方法时，投入时间、复杂度与计算量会呈现指数级增长，然而往往仅能取得1%，甚至0.1%的提升，与真理相去仍然甚远
  - 模型的功能局限：模型只是指引决策的参考，却不能为它的决策本身进行价值判断和承担责任
  - 模型的反馈局限：模型在欠拟合的经济/数据体系中发挥正面作用，当经济/数据体系已经过拟合，模型和体系的系统性风险会加倍扩大（金融危机、评级垄断、高频交易、...）
- 我们到目前所学习与创作的，只是浩如烟海的世界中一块小小的砖瓦，我们生命的盼望却不在这里
- 愿恩惠平安从主基督耶稣临到所见的人

“因为认识耶和华的知识要充满遍地，好像水充满洋海一般。”(以赛亚书11:9)

神爱世人，甚至将他的独生子赐给他们，叫一切信他的，不至灭亡，反得永生。——约翰福音3章16节