

# 数据仓库 开源融合 极致演绎

2016

Teradata 大数据峰会

以手机网络数据获取匿名预付费用户群的基本信息及使用偏好以进行细分营销

David Bloch – 分析及数据战略经理



# 提纲



- **简介**
  - 电信数据状况
  - 我们对大数据和高级分析的观点
  - 我们的大数据和高级分析平台
- **利用大数据识别匿名客户**
  - 问题陈述
  - 假设
  - 寻找行为数据
  - 数据量
  - 识别模式——年轻客户
  - 创建属性列表
  - 选择建模类型
  - 结果
- **结论**
  - 从流程中学到的经验教训
  - 问题和答案



# 简介




## David Bloch

分析及数据战略经理  
沃达丰新西兰公司



- 16年分析、商业智能和软件工程经验
- 4年大数据生态系统构建经验
- 曾在医疗保健、快速消费品、公共事业、媒体、广告和电信行业就职和提供咨询服务
- 在沃达丰消费者部门领导由六名职业分析师组成的团队。



# 我们对大数据和高级分析的观点

大数据带来为客户和业务创建新价值的机会，用户对呈指数式增长的数据集进行捕捉、储存和分析，同时视隐私、许可和安全为第一要务

将数据转变为行动

从核心业务提炼价值  
( 营收提升、成本效率和网络优化 )


利用数据为客户服务

推出创新产品和服务  
( 基于位置的服务、基于产品和个性化的实时数据 )

利用数据驱动市场

数据货币化  
( 面向第三方的数据分析解决方案 )

# 我们的大数据和高级分析平台



# 问题陈述



**新西兰的预付客户无需登记任何详细信息或提供身份信息即可购买预付费Sim卡。**

虽然我们可以通过客户在本公司网络中的流量消耗来瞄准客户，但我们不能识别他们的人口统计学分组，而这也对我们在向预付费客户提供相关产品和服务方面的能力造成限制



# 假设




**如果我们利用合约客户建立人口统计学分组，分析各个组别的行为模式，我们就可以使用这些模式识别匿名客户的类似人口统计学分组。**

如果我们探查16至24岁之间的所有已知客户，了解他们使用的应用类型、使用时间及他们消耗的流量，我们就可以预测有多少匿名客户属于这个年轻组别

# 假设

# 行为数据捕获



# 捕获数据量

**4** 分钟，这是从事件发生到事件进入本公司BD环境中的时间距离

**260** 万个产生本公司网络数据使用流量的连接

**85.4** 万个不同ID地址得到用户访问

**384** 亿次用户应用会话



2016年3月至4月期间，四个星期的数据捕捉

# 识别具有预测价值的潜在数据来源



通过本公司账单平台  
收集的记录信息系统

## 示例：

- 帐单历史
- 设备类型
- 在网时间
- 购买套餐
- 平均营收
- 充值频率
- 年龄（如已知）
- 性别（如已知）
- 总用量



通过我们的大数据平台  
收集的机器生成数据

## 示例：

- 应用使用（如微信、新闻）
- 通话圈和呼叫模式
- 每次Web会话的上传/下载量
- Web会话的当日时间
- 分类使用情况（社交媒体vs新闻网站）

# 识别样本模式——年轻客户



**年轻客户**的夜间数据使用量高于非年轻客户



**年轻客户**在微信等消息应用上的会话数量（即所使用的总时间）更高



**年轻客户**在微博等社交网站的上传量更高



**年轻用户**充值频率更高、单次充值金额更低



**年轻客户**的通话圈更大，比非年轻客户联系的人更多



**年轻客户**更可能参与通过短信渠道开展的优惠和促销

# 创建属性列表，使数据价值标准化



## 195

**个潜在属性**，这是我们在记录系统和机器生成的数据中识别的、具有行为价值的客户人均潜在属性数量

按属性类型识别**价值变量**。

- **帐单信息**——总价值/中间值，得出利用率
- **使用分类信息**——分类应用点击总量/分类应用点击中间值
- **特定应用信息**——应用点击总量、下载总量、上传总量/信息中间值，按当日时间划分

# 标准化数据样本视图



通过本公司账单平台  
收集的记录信息系统


识别因素	属性	标准化价值
节选	智能手机标记	1.000
节选	3G标记	0.000
节选	4G标记	1.000
节选	手机在网时间	0.258
节选	通话分钟数	1.236
节选	短信总计	0.375
节选	流量总计	1.281
节选	所购买流量套餐	0.000
节选	所购买的通话套餐	0.000
节选	每用户平均收入	0.433
节选	亚马逊在线商店	0.010



通过我们的大数据平台  
收集的机器生成数据

识别因素	属性	标准化价值
节选	信息 (10)	8.626
节选	在线商店 (7)	0.050
节选	电子邮件 (3)	6.263
节选	流媒体 (9)	3.446
节选	社交网络 (8)	1.739

# 建模类型——支持向量机



**支持向量机**是一种有人监管的学习模型，允许使用各种类型、各种维度的多个变量

它结合横跨多类变量的关联、分类和回归分析，对利用识别因素、数据和价值字段的强大模型进行训练，然后将之用于预测

# 结果



**78%至88%**

利用多个已知客户样本集合和经过训练的模型对整个客户群体进行分析的预测高度准确性

**98%**

模型具有较高的预测置信度（大于80%）时的预测准确性

**81%**

在客户年龄组方面有合理置信度时对整个预付费客户群里进行预测的准确性

**170k**

在匿名预付费客户群中呈现活跃状态的年轻客户大约总数

# 经验教训



1

行为数据的预测潜力，特别是当日时间和上传量为用户提供有关预付费客户群中类似年轻客户的深入洞见

2

通过将支持向量机与通话圈分析相结合，我们得以进一步提升预测准确性

3

收集更长时间的数据，利用更多的已知年轻客户案例训练模型，有助于提高预测准确性

谢谢！