



高速公路大数据与公路货运统计



中国国家统计局

服务业统计司
2014年10月28日



第一部分

研究背景

第二部分

高速公路大数据介绍及预处理

第三部分

基于大数据的超限车辆规律分析

第四部分

大数据应用启示及前景展望



第一部分

研究背景

一、公路运输统计的重要性及存在的困难

二、结合大数据的公路运输统计新方案简介



一、公路运输统计的重要性及存在的困难

(一)重要性

交通运输



国民经济运行的大动脉

公路运输



交通运输的主要组成部分

公路运输统计



对于反映交通运输行业和国民经济形势具有重要意义



(二) 存在的困难

公路运输统计受行业自身特点影响，存在一些困难，主要集中在公路货运统计上：点多面广、流量流向繁杂、市场准入门槛较低、经营业户极不稳定。这使得公路运输统计对公路运输实际情况反映有限，影响了其服务社会的功效。



二、结合大数据的公路运输统计新方案简介

服务业统计司与交通运输部综合规划司结合大数据设计了公路运输量统计的新方法：通过传统抽样调查获得月度运量基数，采用大数据思路推算月度波动系数，月度运量基数乘以月度波动系数得到当月运量。

客运波动系数

——客运站售票记录

货运波动系数

——高速公路计重收费记录



新方案仍存在一些问题尤其是货运统计部分，因此我司对高速公路大数据展开了更深入的研究，希望能进一步完善公路货运统计以及探索传统统计与大数据结合的途径。



第二部分

高速公路大数据介绍及预处理

一、数据来源及情况

二、原始数据预处理



一、数据来源及情况

(一) 数据来源

高速公路联网监控系统的原始记录。

各类检测监控设备

环形线圈检测器	微波检测器
超声波检测器	视频检测器
计重收费系统	人工输入

对经过车辆实时识别、记录




```

,0,2013-05-12 08:47:55.0,,2301,2013-05-12 08:47:55.0,蓝皖ASM113,1,0,0,0,,0,0
,0,2013-05-12 08:48:14.0,,2301,2013-05-12 08:48:14.0,蓝苏A9NP86,1,0,0,0,,0,0
,0,2013-05-12 08:48:32.0,,2301,2013-05-12 08:48:32.0,蓝皖AZ6571,1,0,0,0,,0,0
0 2013-05-12 08:48:50 0 2301 2013-05-12 08:48:50 蓝皖075012 1 0 0 0 0

```



(二) 数据情况



符合大数据特性

Volume数据体量大


Velocity高速性

Variety多样性

Value价值性高



二、原始数据预处理





(一) 搭建数据处理平台

第二部分

高速公路大数据介绍及预处理

可视化应用分析展示及数据挖掘



数据的前端应用，包括：查询统计，OLAP，图表展示，数据挖掘。

Web应用服务器 (16G内存, 8核CPU)

Tomcat (EzBI)

Rserver (R语言引擎)

主控制节点，负责数据处理分析逻辑解析，任务的分解及结果汇总反馈。

从控制节点，通过心跳技术监控主控节点，以避免单点故障。

EzTable (分布式的内存数据库)

PC服务器A (256G内存, 32核CPU)

PC服务器B (256G内存, 32核CPU)

主节点

Control Server

SQL Server

Mining Server

主节点(灾备节点)

Control Server

SQL Server

Mining Server

心跳控制

数据节点1

数据节点2

数据节点3

数据节点4

.....

数据节点24

数据节点1

数据节点2

数据节点3

数据节点4

.....

数据节点24

两台PC服务器，每台部署24个数据节点，共计48个数据节点。



(二) 对原始记录进行预处理

各省之间的数据格式、字段含义等存在一定差异。

通过预处理，去除或者调整了其中的一些无效数据、异常数据，补充了部分可以估计的不完整数据，对格式、字段含义、代码进行了转化统一，形成了可以进行初步检索、汇总、分析的数据仓库。

以车型代码为例：

省	样例	说明
安徽	1-4, 11-15	标准代码
福建	1-4, 1-5	根据车种代码处理，1-5转换为11-15
广东		非标准代码，根据推测转换
河北	1-4, 1-9	需要转换，1-5转换为11-15，6-9转换为15
河北省京沈片区	1-4, 11-15	标准代码
河南		非标准代码，根据推测转换
湖北		非标准代码，根据推测转换
湖南	1-4, 1-9	1-4转换11-14，5-9转换15
江苏	1-4, 11-15	标准代码
江西	1-4, 11-22	21-22转换15
山东	1-4, 11-15	标准代码
陕西	1-4, 1-5	根据车种代码处理，1-5转换为11-15
上海	1-4, 5-11	5-9转换11-15，10-11转换为15
浙江	1-4, 1-7	1-5转化11-15，6-7转换15
重庆	1-4, 1-5	根据车种代码处理，1-5转换为11-15



(三) 形成具备基本的检索、汇总功能并能进一步统计分析的数据仓库

高速路车辆信息分析平台

数据查询

当前部门 信息


保存 行

过滤区

省: 安徽

客车

货车



检索



第三部分

基于大数据的超限车辆规律分析

一、目的

二、思路和方法

三、具体实施过程

四、初步结论



一、目的

1

熟悉大数据的挖掘分析方法

2

进一步摸清各变量特点

3

为完善公路货运统计打下基础

4

积累统计中应用大数据的经验




二、思路和方法

思路：从大数据本身出发，对已有各变量自身特征进行初步挖掘，基于发现的规律建立合理的模型，选择可行算法展开深层挖掘，分析模型挖掘结果，找出超限车规律。
根据思路确定方法步骤如下：



三、具体实施过程

(一) 数据范围确定：选择数据质量较好的某省初探挖掘






(二) 各变量探索


第三部分

基于大数据的超限车辆规律分析

小时




入口站点





第三部分

车轴



基于大数据的超限车辆规律分析

里程、车货总重、车次

分位数	里程	车货总重	车次
0%	0	0	0
5%	15	18,100	1
10%	25	22,400	1
15%	39	29,600	1
20%	54	36,600	1
25%	75	39,200	1
30%	100	45,200	1
35%	130	52,500	2
40%	166	57,000	2
45%	210	73,600	2
50%	263	87,300	3
55%	324	105,300	3
60%	395	127,100	4
65%	491	161,500	5
70%	640	211,100	7
75%	858	290,400	9
80%	1,239	432,700	12
85%	2,003	729,100	19
90%	4,015	1,562,600	36
95%	11,705	5,030,000	96
100%	1,380,436	331,668,700	6,336



(三) 选择模型和确定建模变量


根据对小时、里程、车轴、车货总重等变量的初步探索，结合考虑需处理的数据量大小，比较多种模型的可行性和结果的有效性后，最终选择聚类分析模型。

按变量对于超限特征分析的解释能力和对于超限分析的重要程度进行筛选，确定放入到模型的变量为：月份、小时、里程、车货总重和车次。

变量	变量字段名	变量中文解释	是否放入模型
V1	province	省份，目前只有山东	不放
V2	year	进入高速路的年，目前是13年和14年	不放
V3	ENTRY_mon	进入高速路时间的月份	
V4	ENTRY_hour	进入高速路时间的分钟，0-23	
V5	entry_station	进入高速路的入口收费站编号	不放
V6	VEHICLE_CLASS_S	车种	不放
V7	VEHICLE_TYPE_S	车型	不放
V8	axis_num	车轴数	不放
V9	sum(DISTANCE)	里程	
V10	sum(TOTAL_WEIGHT)	车货总重	
V11	count	车次	



(四) 模型具体算法





(五) 模型结果分析



经过比较，k等于8的聚类效果优于k=5、6、7、9、10时的效果，故选择k=8的聚类结果：

变量列表	群1	群2	群3	群4	群5	群6	群7	群8
进入高速路的月份	6	7	2	3	10	10	3	6
进入高速路的小时	13	12	12	4	5	18	20	13
里程	586543	1616	1646	1489	1542	2044	2183	99034
车货总重	138981	618	578	704	728	711	738	38653
车次	2632	13	12	14	15	15	16	685
颗粒数量	1483	119328	170986	179667	157086	182685	205430	11625
颗粒数据占比	0.14%	11.60%	16.63%	17.47%	15.28%	17.77%	19.98%	1.13%



第三部分

基于大数据的超限车辆规律分析

	群1	群2	群3	群4	群5	群6	群7	群8
总里程	869842656	192803531	281469518	267586532	242202921	373384933	448405833	1151266010
占总里程百分比	22.73%	5.04%	7.35%	6.99%	6.33%	9.76%	11.72%	30.08%
每辆车的平均里程	222	121	132	103	103	133	138	144
车货重量	206109379067	73690664829	98857784998	126413106809	114330606021	129899985706	151697784241	449339267947
占车货总重百分比	15.26%	5.46%	7.32%	9.36%	8.47%	9.62%	11.23%	33.28%
车次	3902859	1587032	2125577	2590700	2350762	2800574	3246403	7964479
占车次总数百分比	14.69%	5.97%	8.00%	9.75%	8.85%	10.54%	12.22%	29.98%

群1	收费站编号	120106	20101	20704	50305	20801	50304	60108	230207	50205	240104
	颗粒数量	334	324	306	123	105	64	62	54	48	30
	位置	省界	省界	省界	省界	省界	省界	省界	省界	省内	省界
群8	收费站编号	20505	40204	120201	50304	230207	240104	80109	60108	503010	50305
	颗粒数量	364	348	327	310	306	303	297	284	260	259
	位置	省界	省界	省内	省界	省界	省界	港口	省界	港口	省界



四、初步结论



空间规律：

大部分超限车从11个省界站点、2个港口站点进入高速公路（全省共300多个站点）；剩下的小部分超限车辆多从2个省内站点进入高速公路。

时间规律：

超限车辆较多的月份是2、3、4月；较多的小时是夜里的7-9点和0点。

抽样分层基础：

各自具有明显特征的8个群，可作为在运量基数中考虑超限的基础。



第四部分

大数据应用启示及前景展望

一、大数据应用启示

二、前景展望



一、大数据应用启示

大数据应用需要在大量摸索尝试中，确定研究分析方向，并不断调整改进。

大数据挖掘中，简单算法时常比复杂算法更实用。

获得大数据及对大数据预处理形成可以进行分析操作的数据仓库至关重要。



二、前景展望

继续挖掘超限车规律，在统计运量基数时充分考虑超限造成的数据差距,设法加以完善。

深入研究高速公路运量变化与公路运量变化的关系,寻找完善波动系数的方法。

增长时间序列，研究高速公路运量与宏观经济的深层关系。



谢谢!

