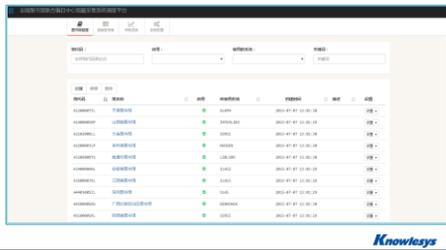


2.3 系统截图——图书馆管理



2.3 系统截图——采集进度

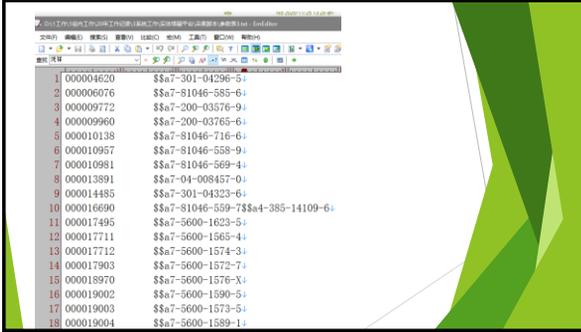
| 已采集条数 | 初始条数 | 覆盖率 | 采集率 | 比较 (采集/初始条数) |
|-------|--------|--------|---------|--------------|
| 2100 | 14557 | 14.42% | 14.03% | 101.7% |
| 4318 | 144943 | 3.05% | 13.854% | 21.7% |
| 725 | 14373 | 5.04% | 4.938 | 101.8% |
| 6543 | 402118 | 1.63% | 16.765% | 10.3% |
| 1799 | 278098 | 0.65% | 27.874% | 4.1% |
| 768 | 18740 | 4.1% | 18.98% | 21.6% |
| 17791 | 346511 | 5.13% | 29.723% | 58.3% |
| 740 | 21573 | 3.43% | 11.235% | 30.5% |
| 3053 | 696027 | 0.44% | 54.777% | 12.4% |
| 5497 | 109288 | 5.03% | 4.969% | 101.6% |
| 7274 | 326225 | 2.23% | 13.806% | 60.1% |

实体资源馆藏工作的背景

- 待处理馆藏量巨大，存量数据超过1.2亿条书目数据，每年新增约1000万条书目数据；
- 数据质量参差不齐，数据来源复杂。
- 基础查重算法：十四字段查重；O10\$a。
- 改进方案：结合八字段查重，对不同的查重结果设置区间，减少查重者需要消耗的精力
- 查重数据量巨大导致传统查重方法无法达到实际效果；
- 查重工作人员的经验复用问题；
- 查重工作流程标准化问题。

查重工作界面

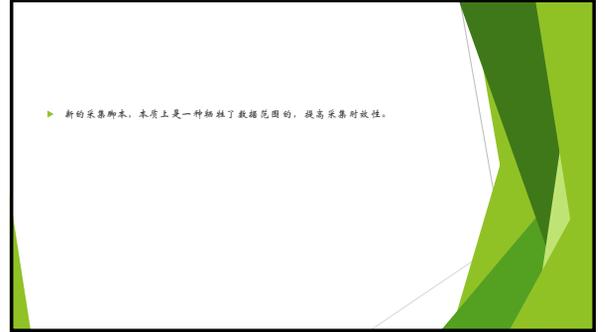




```

1 000004620  $$a7-301-04296-5
2 000006076  $$a7-81046-585-6
3 000009772  $$a7-200-03576-9
4 000009960  $$a7-200-03765-6
5 000010138  $$a7-81046-716-6
6 000010957  $$a7-81046-558-9
7 000010981  $$a7-81046-569-4
8 000013891  $$a7-04-008457-0
9 000014485  $$a7-301-04323-6
10 000016690  $$a7-81046-559-7$$a4-385-14109-6
11 000017495  $$a7-5600-1623-5
12 000017711  $$a7-5600-1565-4
13 000017712  $$a7-5600-1574-3
14 000017903  $$a7-5600-1572-7
15 000018970  $$a7-5600-1576-X
16 000019002  $$a7-5600-1590-5
17 000019003  $$a7-5600-1573-5
18 000019004  $$a7-5600-1589-1

```



► 新的采集脚本，本质上是一种牺牲了数据范围的，提高采集针对性。