北大附中 2019 学段汇报

猴子打字项目

作者：李天桐 谢梓涵 周翟恩和

指导教师：王楚

（以上姓名不分先后）

日期：2019 年 6 月 26 日

开源项目地址：https://github.com/bdfzoier/Monkey_Type

目录

1 引言

猴子打字项目是一个能自动分析学习字典，利用一阶马尔可夫链生成类似英语单词，满足英语单词基本发音和规则的字符串的程序。

相信大家都听说过”脸滚键盘“，虽然这也是一个生成单词的方法，但是这种单词通常都不会满足发音规则等任何规则，就更不用提能不能生成真正的单词了。它的概率大约相当于连续买 4 张彩票，有 3 张都中了 500 万的概率。

但是，利用机器学习，可以让几乎所有生成的单词都可以发音，同时可以把生成真单词的概率提升到 20%，这就略有些困难，本论文就提供了一个可共借鉴的生成思路。

关键词：机器学习、马尔可夫链、后缀数组（SA）、生成单词

2 基本原理

采用一个词库，把所有单词拆成连续元音+连续辅音+连续元音+连续辅音……的组合，比如 traditional=tr+a+d+i+t+io+n+a+l。然后建有向无权图，将第 i 个组合向第 i+1 个组合连上一条边，从 start 节点向第 1 个组合连一条边，从最后一个组合向 end 节点连 1 条边。比如当我们采用了 great,grasp,grease,good 这 4 个单词的词库，那么我们建成的图将会是如下形式：

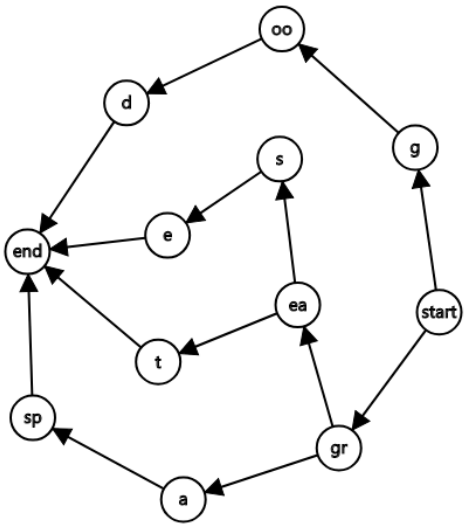

采用类似网络流建模的方式，我们列出 Start 及 End 节点，造点连边后根据概率和随机生成的长度生成单词。把路径上经过的所有节点连起来，就是一个新单词了。显然，词的数量越多，可能产生的新单词的数量也就越多。~~貌似这 4 个单词还没法生成任何新单词~~

再举一个例子，pumpkin 和 jumping 生成的图是这样的

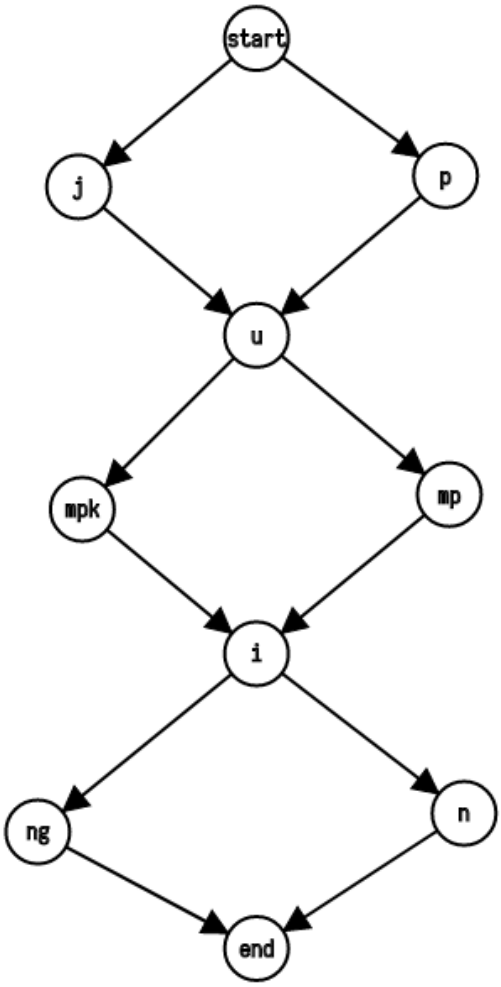

不难从图中看到，一共有 8 种方式从起点出发并到达重点，对应生成的单词分别为：

jumping
jumpkin
jumpking
jumpin
pumping
pumpin
pumpkin
pumpking

3 实现计划

实现时，我们分为 4 步实现这个项目：

第 1 步，寻找一个合适的单词库。

第 2 步，编写一个专门用来分开所有单词的程序，这个程序将会把所有的单词拆分成续元音+连续辅音+连续元音+连续辅音……的组合。

第 3 步，编写用于存储数据的结构体，后面所有函数封装到这个结构体里面。

第 4 步，编写一个用来随机寻找一个组合的程序，我们在这里做到了按概率比例来随机生成：例如有 5 个单词有 sp+oi 的组合，1 个单词有 sp+e 的组合，那么我们编写的程序随机生成 60000 个组合，将会有大约 50000 个 sp+oi 和 10000 个 sp+e。

第 5 步，也就是展示用程序，将会从 start 节点随机一个路径到 end 节点：每一次采用随机一个组合的方法找到下一步，然后用递归的方法找到路径，并输出。

第 6 步，进行量化分析，也就是类似于测算生成出的 10000 个单词中，有多少个是真正的英文单词。这样，就可以得出大致的相似度以及这个程序到底有多“聪明”。

4 小组分工

周翟恩和负责完成第 2、3、4、5 步，撰写论文；

谢梓涵负责完成 API，对代码进行常数优化，撰写论文；

李天桐负责完成第 1、6 步，撰写论文。

5 实现过程

5.1 单词库

我们采用了英语四级词汇，大约有 4300 个。事实上，我们之前采用过 10000 个单词甚至更大的一个 7000000 个单词的大型词库，但经过人工查询后发现很多单词都不是正常的英文单词（如地名，带“-”的单词，或者没有元音的单词），这样生成出来的“单词”反而更不像正常的英语单词。因此，我们选择了英语四级词汇作为我们机器学习的用具。另外，单词量过大也不容易快速求解~~以及保护电脑健康。~~

5.2 分开单词

我在这里采用了暴力拆解的方法，直接把所有的字母组合拆出来当作图的节点，并记录下一个节点。我们把这一部分以及 3、4 部分写成了三个头文件。

这里的时间复杂度为$\Theta(4300|s|)$，其中$|s|$代表单词的长度，平均长度大约在10~15 左右。

5.3 存储数据

为了存储和处理方便，以及节省空间，我们将每个元/辅音组利用谢梓涵通过 Splay 算法全都映射为一个整数。Splay 是一种平衡树，可以维护 STL 中的 map 和 set 等容器的所有功能，且满足均摊复杂度为$\Theta(\log N)$。

我们存储数据采用的是邻接表，即将每个节点的所有子节点全部顺序存下在一个数组里。

5.4 随机一个组合

在生成单词中遇到一个问题便是由于最终可以生成的单词过多，甚至由于图中的自环（o 后面可以接 n，n 后面可以接 o），会导致我们在生成的过程中出现死循环，所以我们需要一个强有力的方法来在搜索过程中进行筛选，放弃某些情况，避免我们程序发生死循环。

由于可以生成的单词数量随着深度的增加，呈指数级增长，所以最有效的一个筛选方法就是控制搜索的深度，即单词由几个声/韵母组构成。 另一个方法即是只随机生成部分的单词，而这里遇到的问题就是，因为空间问题，我们不得不把所有相同的节点压缩到 1 个节点，但是我们在节点对象中封装了一个 prop 变量，用于存储压缩前该组合在其父节点的所有出现的次数。而它的生成概率将与 prop 成正比。具体来说，第i个元素的生成概率即为$\frac{prop_i}{\sum prop}$。但是 c++中关于随机数的函数只有一个，其功能也十分简陋，即简单的生成一个随机的整数，那么我们如何实现上述的操作呢？

对于一个数组，如下

index→	1	2	3
value	10	31	12
prop	5	1	4

我们的解决办法是对其 prop 属性求前缀和，如下

index→	0	1	2	3
sum	0	5	6	10

然后先生成一个随机数，这里假设是 157，将其对 sum[3]，即所有项的和取余，得到 7。

发现 sum[3]>7>=sum[2]，所以这次随机得到的结果便是下标为 3，值为 value[3]，即 12 这个数。

当这个数字对$\sum prop$取余时，其可以为$[0, \sum prop)$中的任意一个数，每个数概率相等，而如果该数在[sum[i-1],sum[i])之间，共有 prop[i]个数，所以其概率恰好为 $\frac{prop_i}{\sum prop}$。

5.5 DFS 生成伪单词

DFS 就是正常的深度优先搜索。先通过随机生成的组合来建成一个有向图，拥有 **start** 节点及 **end** 节点。深度优先搜索即从 **start** 节点开始搜索。由于图可能存在环状结构，因此可以通过给定的深度（单词部分的长度）来判断单词是否结束。通过此种方法，可以按照某种顺序生成出伪单词。

这一步的原始数据完全依赖于上一步的随机单词。如果随机选出的单词出现了 o 接 n，n 接 o 的情况，生成出的单词将会出现像 nonononononono 一样的单词，所以对于 dfs，我们同样需要对深度进行限制。

如下图情况：

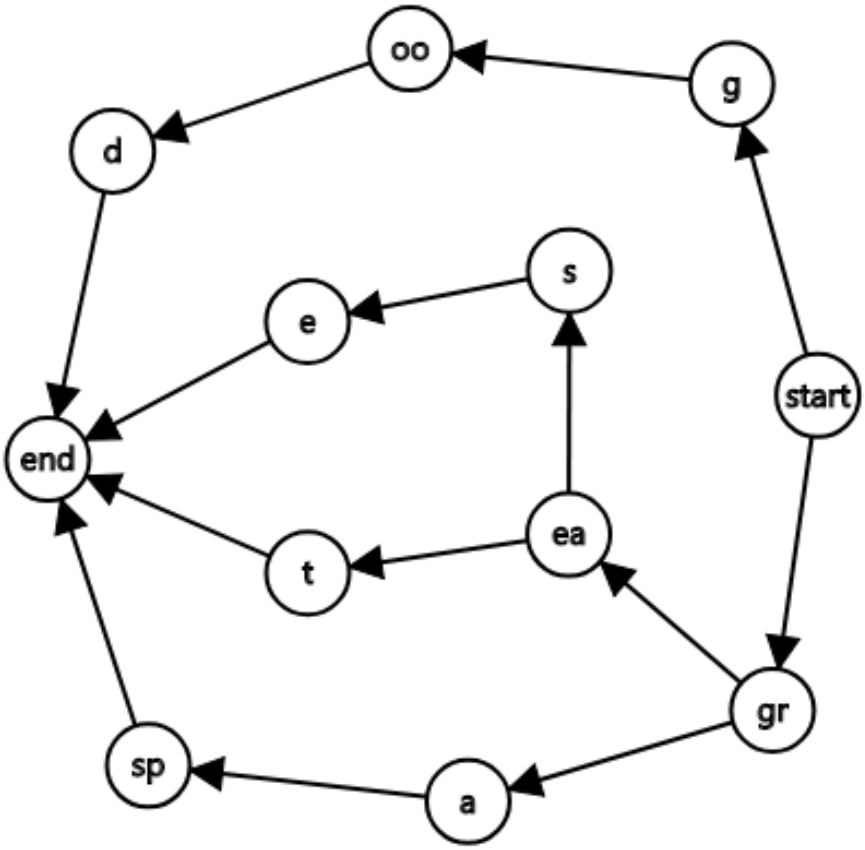

这样，如果深度为 4，从 start 节点开始进行 DFS 搜索的序列为：start → g → oo → d → end ← d ← oo ← g ← start → gr → ea → s → e ← s ← ea → t → end ← t ← ea ← gr → a → sp → end ← sp ← a ← gr ← start （注：→表示此深度优先搜索（DFS）算法的搜索顺序，而←表示回溯过程）。

最后在结尾时，必须进行判断是否到达 end 节点来决定是否输出 DFS 生成的伪单词，如果是因为深度限制导致的搜索停止则不能输出。（不然测试时发现测试时发现会生成一大堆相同的单词，或者不完整（刚生成了一半）的单词就被输出了）

5.6 量化分析

量化分析部分，我们还需要两个部分： 部分 1，分别判断单词是否存在我们使用的小词库，以及网上找到的可看为包含所有单词（479000 个单词）的大词库。 部分 2，计数。

对于部分 1，我们首先设计了一个$\Theta(4300 \cdot \log 4300 \cdot |s|) \approx \Theta(500000)$的暴力算法，在谢梓涵经过字典树优化之后直接将复杂度降到了$\Theta(26 \cdot |s|) \approx \Theta(300)$。~~不论是对电脑的损伤程度还是~~时间和空间占用量都有所减少。

对于部分 2，我们在测试中采用了深度为 4~10 的随机生成函数。

经过计数，我们发现在生成的一千个单词中，有 214 个是英语单词（存在大词库中），有 47 个是 4300 个单词的小词库中有的单词，而剩下的单词大多都与真正的英语单词十分相像，并且可以利用自然拼读法读出来。（所有生成的单词见这里）

6 与马尔可夫链的关系？

6.1 什么是马尔可夫链？

马尔可夫链指的是一条链，当在这条链上进行随机移动时，第 i 次移动不受到任何历史移动的影响。对于我们进行单词生成，或者生成有意义的句子这类算法时，而下一个移动到达的的地方是在该节点的所有子节点中随机选择的，每一个子节点被选中的概率与其出现的次数成正比。

6.2 我们对这个问题的建模与马尔可夫链是否有关系？

在这里，我们可以发现，其实我们建出的图并不是传说中的“无权图”，假设一条边从 u 连向 v，那么它的权值实际上是$\frac{prop_v}{\sum_{w \in nxt_u} prop_w}$，其中$nxt_u$为所有$u$的后继节点。同时，该图满足$\sum_{v \in nxt_u} W_{u,v} = 1$，其中$W_{u,v}$表示边$< u, v >$的权值。

可见，我们建的模型其实就是一个马尔可夫链，因为我们这个图是静态的，所以每次移动不会受到任何历史移动的影响。

7 项目意义与展望

这个项目可能在拼写检查中有所意义，因为生成单词的逆操作其实就是检查某个单词是否合法，如果我们的程序能获得足够的单词数据，就能判断某个单词是否在我们生成的图中存在。

如果利用这种算法改进拼写检查的算法，便不需要将所有的单词都存储下来（因为我们的算法在存储过程中仅仅会保留单词之间有差异的部分），能有效的节省存储空间。

不过如果需要实现到这一步，我们需要大幅提高我们生成单词过程的精确度，才能提供足够的准确拼写检查。

8 参考文献/数据

1. https://github.com/dwyl/english-words 一个较大的英语单词库
2. https://blog.csdn.net/songzitea/article/details/8864122 利用马尔可夫链生成有意义的句子。

9 致谢

感谢尊敬的王楚老师，肖然老师为我们的汇报提供了选题上的意见，以及为对我们在研究过程中不懂得一些问题进行答疑。

感谢 etherpad 提供在线写论文的平台。

感谢 GitHub 提供的开源项目平台。

感谢海淀图书馆以及某咖啡厅提供集体讨论的地方。