Презентация к дипломной работе

Разработка многопрофильной системы информационного поиска

Основные компании

- Amazon
- Google
- Яндекс
- Amazon
- Twitter
- Microsoft

Характеристики сложноструктурированных данных

1. Внутренняя интерпретация.
2. Наличие внутренней структуры связей.
3. Шкалирование.
4. Погружение в пространство с семантической метрикой.
5. Наличие активности.

Используемые алгоритмы

- PageRank
- DBScan
- Rock
- Наивный байесовский классификатор
- Семантические сети

Области применения системы информационного поиска

- Поиск информации.
- Формирование рекомендаций.
- Установление авторства.
- Проверка на плагиат.
- Автоматическая генерация текстов для SEO (поисковой оптимизации).
- Лингвистический анализ литературных текстов.
- Корректировка текстов и исправление опечаток.

Алгоритм PageRank

1. Каждой странице присваиваем вес равной единице.
2. Подсчитываем количество исходящих связей для каждой страницы.
3. $$pageRank(A) = 1 - d + d \bullet \left(\frac{pageRank(T1)}{C(T1)} + \ldots + \frac{PageRank(Tn)}{C(Tn)} \right)$$

   Вычисляем ранг каждой страницы с помощью формулы. Где A – страница, ранг которой необходимо найти, C(T1) – количество исходящих ссылок, d – коэффициент затухания.

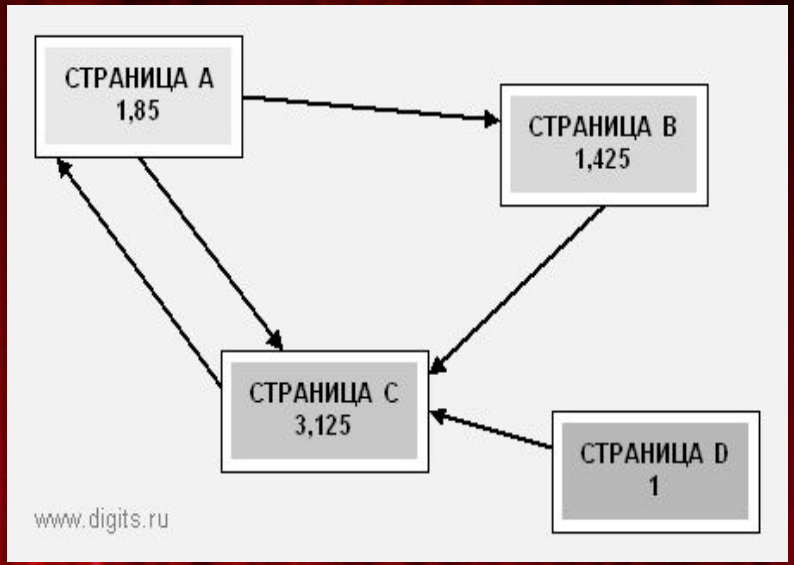

Место для блок-схемы

Алгоритм ROCK

```
Procedurecluster (S, k)
Begin
1. link := compute-links (S)//Вычисляем связи в множестве точек S
2. for each s from S do
3. q[s] := build-local-heap (link,S)//Из каждой точки множества S на основе связей
      формируем кластер
4. Q:=build-global-heap (S,q) //Содержит список всех кластеров множества S
5. whilesize (Q) >kdo {//Формируем кластеры, точки, которых имеют максимальное
      число связей до тех пор, пока не получим желаемое число кластеров
6. u := extract-max (Q)
7. v := max (q[u])
8. delete (Q,v)
9. w:= merge (u,v)
10. for each x from (q[u] or q[v]) do {
11. link [x,w] := link [x,u] + link [x,v]
12. delete (q[x],u); delete (q[x],v)
13. insert (q[x],w,g(x,w)); insert (q[w],x,g(x,w));
14. update (Q,x,q[x])
15. }
16. insert (Q,w,q[w])//Добавляем кластер в список всех кластеров
17. deallocate (q[u]); deallocate (q[v]);
18. }
end.
```

Алгоритм DBSCAN

```
public List<Cluster> cluster() {
int clusterId = getNextClusterId();
for(DataPointp : points) {
if(isUnclassified(p) ) {//Проверяем классифицировали ли мы данную точку.
boolean isClusterCreated = createCluster(p, clusterId);
      //Создаемкластердлякаждойточки
if( isClusterCreated ) {
clusterId = getNextClusterId();
      }
    }
  }
  List<Cluster> allClusters = new ArrayList<Cluster>();
for(Map.Entry<Integer, Set<DataPoint>> e : clusters.entrySet()) {
    String label = String.valueOf(e.getKey());//Создаем кластер и имя длянего
    Set<DataPoint> points = e.getValue();
if( points != null && !points.isEmpty() ) {
      Cluster cluster = new Cluster(label, e.getValue());
allClusters.add(cluster);
    }
  }
returnallClusters;//Возвращаем список всех кластеров, которые были созданы
}
```

Алгоритм DBSCAN

```
private boolean createCluster(DataPoint p, Integer clusterId){
Set<DataPoint> nPoints = findNeighbors(p, eps);
if( nPoints.size() < minPoints ) {
assignPointToCluster(p, CLUSTER_ID_NOISE);//Есликоличествоточекокружностименьше, чемminPoints,
        присваиваемточкезначение «Шум»
isClusterCreated = false;
   } else {
assignPointToCluster(nPoints, clusterId);  //Иначедобавляемточкувкластер
nPoints.remove(p);//Удаляем точку из рассмотрения
while(nPoints.size() > 0 ) {  //Просматриваем все точки, если нашли точку, которую уже рассматривали
        то ставим ей статус пограничной, добавляем в кластер и удаляем из рассмотрения
DataPoint nPoint = nPoints.iterator().next();
       Set<DataPoint> nnPoints = findNeighbors(nPoint, eps);
if( nnPoints.size() >= minPoints ) {
for(DataPoint nnPoint : nnPoints ) {
if( isNoise(nnPoint) ) {
assignPointToCluster(nnPoint, clusterId);  //Добавляемточкукккластеру
            } else if( isUnclassified(nnPoint) ){
nPoints.add(nnPoint);
assignPointToCluster(nnPoint, clusterId);}          }      }
nPoints.remove(nPoint);  //Удаляемточкуизрассмотрения
}
isClusterCreated = true;
  }
return isClusterCreated;
}
```

Наивный байесовский классификатор

- Место для блок-схемы.