Bilgiye Erişim Sistemleri

(Information Retrieval Systems-IR)

Prof.Dr. Banu Diri

Örnek IR Sistemleri

- Kütüphane veritabanları
  anahtar kelime, başlık, yazar, konu vs. ile büyük veritabanlarında arama (www.library.unt.edu)
- Metin Tabanlı Arama Motorları (Google, Yahoo, Altavista vs.)
  Anahtar kelimelerle arama
- Multimedya Arama (QBIC-IBM's Query By Image Content, WebSeek-**A Content-Based Image and Video Catalog and Search Tool for the Web**)
  Görsel öğelerle arama (şekil, renk vs.)
- Soru Cevaplama Sistemleri (AskJeeves, Answerbus)
  Doğal dille arama
- Hakia (http://www.hakia.com/)

IR Sistem Mimarisi

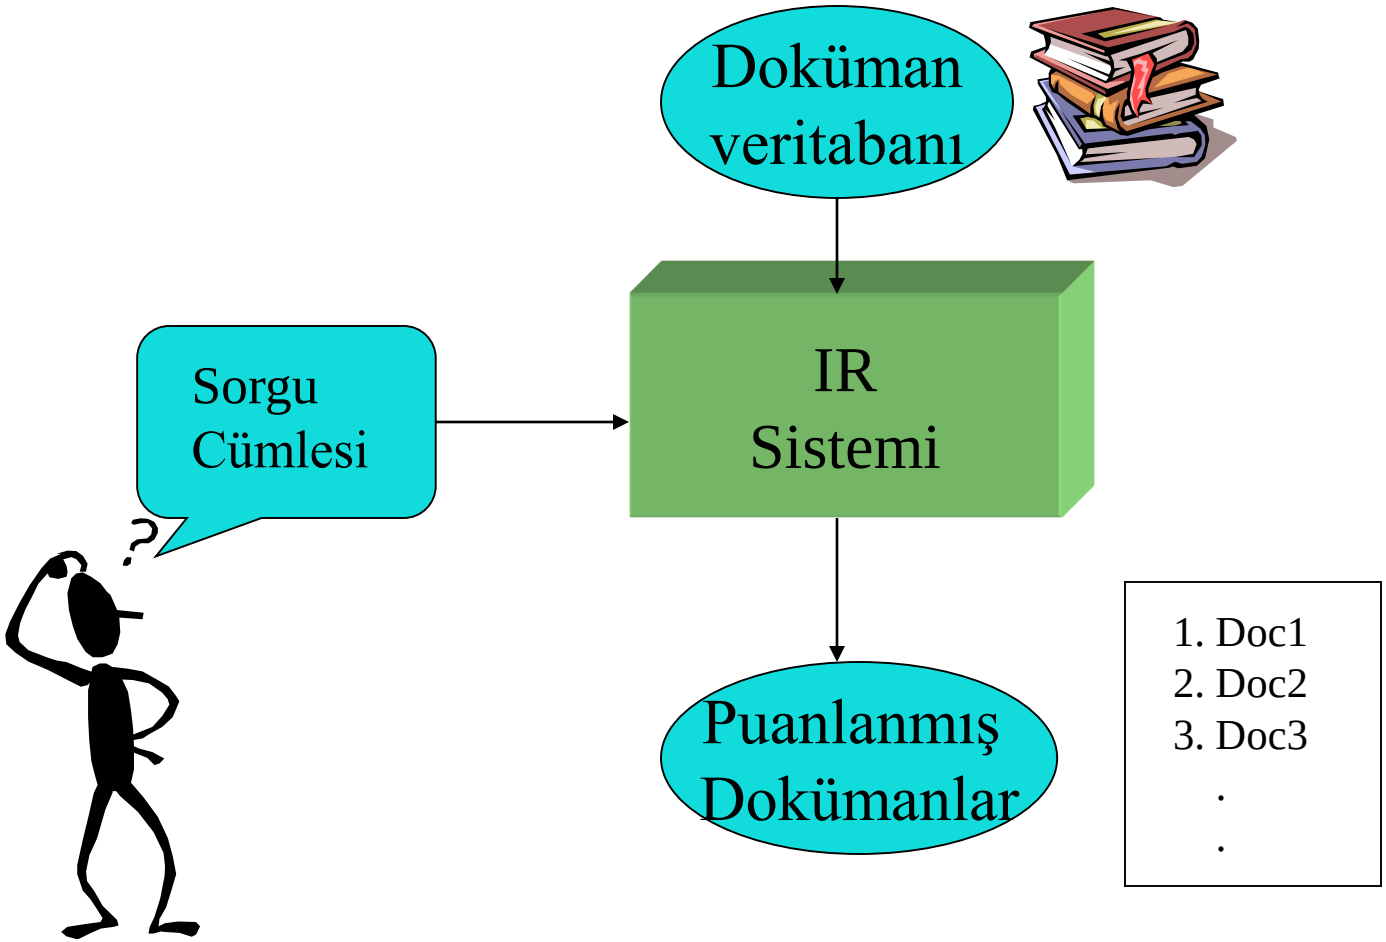

Arama Motoru Mimarisi

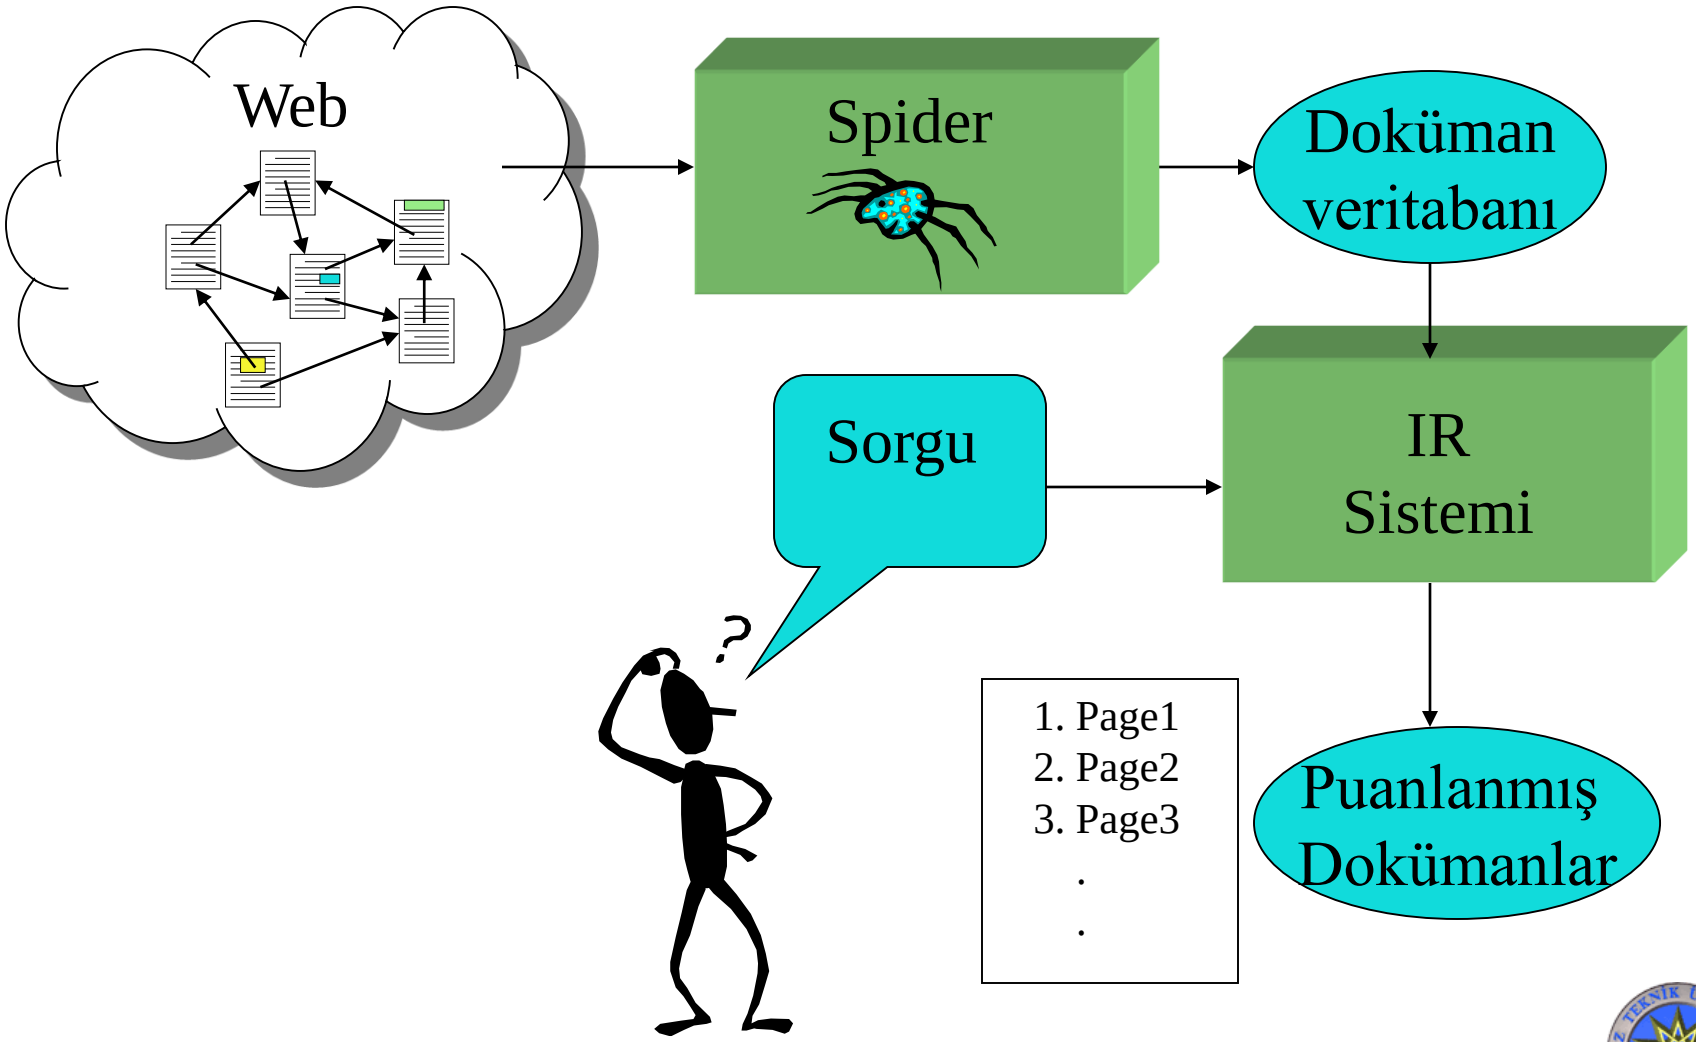

IR –Modelleri

Etkili bir IR yapmak için, dokümanlar uygun bir gösterim formuna dönüştürülmelidir. Modeller iki boyutlu olarak ele alınır.

❖ **Matemetiksel Modeller** (*Set-theoretic models, Algebraic models, Probabilistic models)*

❖ Modelin özellikleri (*without term-interdependencies, with term-interdependencies)*

Matemetiksel Modeller

Küme-Kuramsal Modeller (Set-theoretic models)

Dokümanlar kelimeler veya ifadelerin kümesi olarak gösterilir.

En çok bilinen modeller:

Standard Boolean Model

Extended Boolean Model

Fuzzy Retrieval

Standard Boolean Model

Boolean Information Retrieval (BIR) , Boolean Logic ve Klasik Küme teorisine dayanır.

Retrieval is based on whether or not the documents contain the query terms.

- T = {t1, t2, ..., tj, ..., tm} of elements called index terms (e.g. words or expressions)
- D = {D1, ..., Di, ..., Dn}, where Di is an element of the powerset of T of elements called documents.
- Given a Boolean expression - in a normal form - Q called a query as follows:
- Q = (Wi OR Wk OR ...) AND ... AND (Wj OR Ws OR ...), with Wi=ti, Wk=tk, Wj=tj, Ws=ts, or Wi=NON ti, Wk=NON tk, Wj=NON tj, Ws=NONts where ti means that the term ti is present in document Di, whereas NON ti means that it is not.

Retrieval, consisting of two steps, is defined as follows:

1. The sets Sj of documents are obtained that contain or not term tj (depending on whether Wj=tj or Wj=NON tj) : Sj = {Di|Wj element of Di}
2. Those documents are retrieved in response to Q which are the result of the corresponding sets operations, i.e. the answer to Q is as follows:

UNION (INTERSECTION Sj)

Örnek

Let the set of original (real) documents be, for example D = {D1, D2, D3} where

D1 = Bayes' Principle: The principle that, in estimating a parameter, one should initially assume that each possible value has equal probability (a uniform prior distribution).

D2 = Bayesian Decision Theory: A mathematical theory of decision-making which presumes utility and probability functions, and according to which the act to be chosen is the Bayes act, i.e. the one with highest Subjective Expected Utility. If one had unlimited time and calculating power with which to make every decision, this procedure would be the best way to make any decision.

D3 = Bayesian Epistemology: A philosophical theory which holds that the epistemic status of a proposition (i.e. how well proven or well established it is) is best measured by a probability and that the proper way to revise this probability is given by Bayesian conditionalisation or similar procedures. A Bayesian epistemologist would use probability to define, and explore the relationship between, concepts such as epistemic status, support or explanatory power.

Let the set T of terms be:

T = {t1 = Bayes' Principle, t2 = probability, t3 = decision-making, t4 = Bayesian Epistemology}

Then, the set D of documents is as follows:

D = {D1, D2, D3} where
D1 = {Bayes' Principle, probability}
D2 = {probability, decision-making}
D3 = {probability, Bayesian Epistemology}

Let the query Q be: **Q =** probability ***AND*** decision-making

1. Firstly, the following sets S1 and S2 of documents Di are obtained (retrieved):

S1 = {D1, D2, D3} →*probability*
S2 = {D2} →decision-making

2. Finally, the following documents Di are retrieved in response to Q:

{D1, D2, D3} INTERSECTION {D2} = {D2}
This means that the original document D is the answer to Q.

Avantajları

✓Formüle edilmesi ve geliştirilmesi kolaydır.

Dezavantajları

✓Birden fazla doküman sonuç olarak döndürülebilir
✓Sonuçların önemine göre sıralanması güçtür
✓Sorgu cümlesinde yer alan boolean ifadenin yorumlanması güç olabilir
✓Bütün terimler eşit ağırlıktadır
✓*information retrieval* dan ziyade *data retrieval* olarak çalışır

Matemetiksel Modeller

Küme-Kuramsal Modeller (Set-theoretic models)

Dokümanlar kelimeler veya ifadelerin kümesi olarak gösterilir.

En çok bilinen modeller:

Standard Boolean Model
Extended Boolean Model
Fuzzy Retrieval

Extended Boolean Model

- Genişletilmiş Boolean Modelinin amacı, Boolean modelinin dezavantajlarının üstesinden gelmektir
- Boolean modeli sorgulardaki terim ağırlıklarını dikkate almaz
- Bir Boole sorgusunun sonuç kümesi genellikle ya çok küçük ya da çok büyüktür
- Genişletilmiş Boolean Modeli, Vektör Uzayı Modelinin özelliklerini Boolean cebirinin özellikleriyle birleştirir
- Sorgular ve belgeler arasındaki benzerliği sıralar

Tanım

- Genişletilmiş Boolean modelinde, bir belge bir vektör olarak temsil edilir.
- Her i boyutu, belgeyle ilişkili ayrı bir terime karşılık gelir.
- dj belgesi ile ilişkili Kx teriminin ağırlığı, normalleştirilmiş terim frekansı ile ölçülür ve şu şekilde tanımlanabilir:

$$w_{x,j} = f_{x,j} * \frac{Idf_x}{max_i Idf_x}$$

- Burada Idfx ters belge frekansıdır. dj belgesi ile ilişkili ağırlık vektörü şu şekilde gösterilebilir:

$$\mathbf{v}_{d_j} = [w_{1,j}, w_{2,j}, \ldots, w_{i,j}]$$

İki boyutlu örnek

Kx ve Ky terimlerinden oluşan uzay göz önüne alındığında, ilgili terim ağırlıkları w1 ve w2 olsun.

Böylece, $q_{or} = (K_x \vee K_y)$ ve $q_{and} = (K_x \wedge K_y)$ sorguları için benzerlik

$$sim(q_{or}, d) = \sqrt{\frac{w_1^2 + w_2^2}{2}}$$

$$sim(q_{and}, d) = 1 - \sqrt{\frac{(1 - w_1)^2 + (1 - w_2)^2}{2}}$$

şeklinde hesaplanır.

Fikrin genelleştirilmesi ve P-normları

2B genişletilmiş Boole modeli örneğini Öklid uzaklığını kullanarak daha yüksek t-boyutlu uzaya genelleştirebiliriz.

Bu, mesafe kavramını p-mesafeleri içerecek şekilde genişleten P-normları kullanılarak yapılabilir; burada $1 \leq p \leq \infty$ yeni bir parametredir. Genelleştirilmiş sorgu şu şekilde verilir:

$$q_{or} = k_1 \vee^p k_2 \vee^p .... \vee^p k_t$$

- q_{or} ve d_j nin benzerliği şu şekilde tanımlanabilir:

$$sim(q_{or}, d_j) = \sqrt[p]{\frac{w_1^p + w_2^p + ... + w_t^p}{t}}$$

- Genelleştirilmiş ayrık sorgu şu şekilde verilir:

$$q_{and} = k_1 \wedge^p k_2 \wedge^p .... \wedge^p k_t$$

- q_{and} ve d_j nin benzerliği şu şekilde tanımlanabilir:

$$sim(q_{and}, d_j) = 1 - \sqrt[p]{\frac{(1-w_1)^p + (1-w_2)^p + ... + (1-w_t)^p}{t}}$$

Örnek

q = (K_1 and K_2) or K_3 sorgusunu düşünün. Sorgu q ve belge d arasındaki benzerlik aşağıdaki formül kullanılarak hesaplanabilir:

$$sim(q, d) = \sqrt[p]{\frac{(1 - \sqrt[p]{(\frac{(1-w_1)^p + (1-w_2)^p}{2})})^p + w_3^p}{2}}$$

Vektör Uzayı Modeli

- Varsayım: Kelimeler birbirinden bağımsızdır

Eldekiler:

N doküman
1 sorgu

$$\begin{array}{c|cccc} & T_1 & T_2 & .... & T_t \\ D_1 & d_{11} & d_{12} & ... & d_{1t} \\ D_2 & d_{21} & d_{22} & ... & d_{2t} \\ : & : & : & & : \\ : & : & : & & : \\ D_n & d_{n1} & d_{n2} & ... & d_{nt} \end{array}$$

$$Q \quad q_1 \quad q_2 \quad ... q_t$$

Vektör Uzayı Modeli metin belgelerini, örneğin dizin terimleri gibi tanımlayıcıların vektörleri olarak temsil etmek için kullanılan cebirsel bir modeldir.

Dokümanlar ve sorgular vektör olarak temsil edilir.

$d_j = (w_{1,j}, w_{2,j}, \ldots, w_{t,j})$
$q = (w_{1,q}, w_{2,q}, \ldots, w_{t,q})$

- Her boyut ayrı bir terime karşılık gelir
- Bir terim belgede geçiyorsa, vektördeki değeri sıfırdan farklıdır
- Bu değerleri hesaplamanın birkaç farklı yolu vardır, en iyi bilinenlerden tf-idf ağırlıklandırmasıdır

Terim Ağırlıklarının Bulunması

- *j*. terimin *i*. doküman için ağırlığı:

$$d_{ij} = tf_{ij} \bullet idf_j = tf_{ij} \bullet \log_2 (N / df_j)$$

- $tf \rightarrow$ Terim Frekansı
  - Bir dokümanda sıkça geçen ancak diğer dokümanlarda pek bulunmayan terimin ağırlığı yüksek olur.
  - $max_l\{tf_{li}\}$ = *i*. dokümanda en çok geçen terimin frekansı
  - Normalizasyon: terim frekansı $= tf_{ij} / max_l\{tf_{li}\}$

$$w = tf/tfmax$$

$$w = IDF = log(D/d)$$

$$w = tf*IDF = tf*log(D/d)$$

$$w = tf*IDF = tf*log((D - d)/d)$$

Örnek

✓İçerisinde «cow» kelimesinin 3 kez geçtiği, 100 kelime içeren bir belge düşünün.
✓Bu durumda «cow» için terim frekansı (*tf*) (3 / 100) = 0,03'tür
✓Şimdi, elimizde 10 milyon doküman olduğunu ve «cow» kelimesinin sadece bin tanesinde geçtiğini varsayalım.
✓Ters belge sıklığı şu şekilde hesaplanır

$\log(10\,000\,000 / 1\,000) = 4$

tf-idf puanı da bu niceliklerin çarpımıdır:

$0.03 \times 4 = 0.12$

➢İki vektör arasındaki açının kosünüs değeri, iki vektör arasındaki benzerliğin bir ölçüsü olup, **Kosinüs Benzerliği (Cosine Similarity)** olarak adlandırılır.

➢ Kosinüs fonksiyonunun sonucu, açı 0 olduğunda 1'e eşittir ve açı başka herhangi bir değerde olduğunda 1'den küçüktür.

➢ İki vektör arasındaki açının kosinüsünün hesaplanması, iki vektörün kabaca aynı yönü gösterip göstermediğini belirler.

$$\text{similarity} = \cos(\theta) = \frac{A \cdot B}{\|A\|\|B\|} = \frac{\sum_{i=1}^{n} A_i \times B_i}{\sqrt{\sum_{i=1}^{n} (A_i)^2} \times \sqrt{\sum_{i=1}^{n} (B_i)^2}}$$

- İki vektör arasındaki açının kosinüsü
- Inner product vektör büyüklükleriyle normalize edilir.

$$\text{CosSim}(D_i, Q) = \frac{\sum_{k=1}^{t} (d_{ik} \bullet q_k)}{\sqrt{\sum_{k=1}^{t} d_{ik}^2} \bullet \sqrt{\sum_{k=1}^{t} q_k^2}}$$

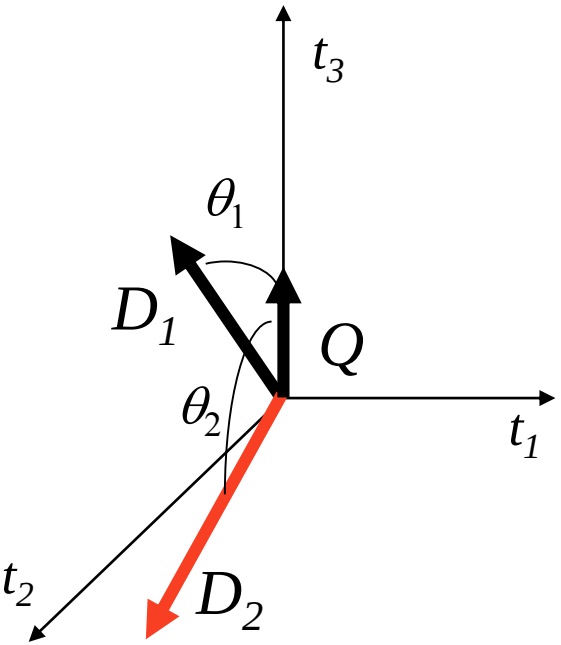

Grafiksel Gösterim

$D_1 = 2T_1 + 3T_2 + 5T_3$ CosSim(D_1 , Q) = 0.81
$D_2 = 3T_1 + 7T_2 + T_3$ CosSim(D_2 , Q) = 0.13
$Q = 0T_1 + 0T_2 + 2T_3$

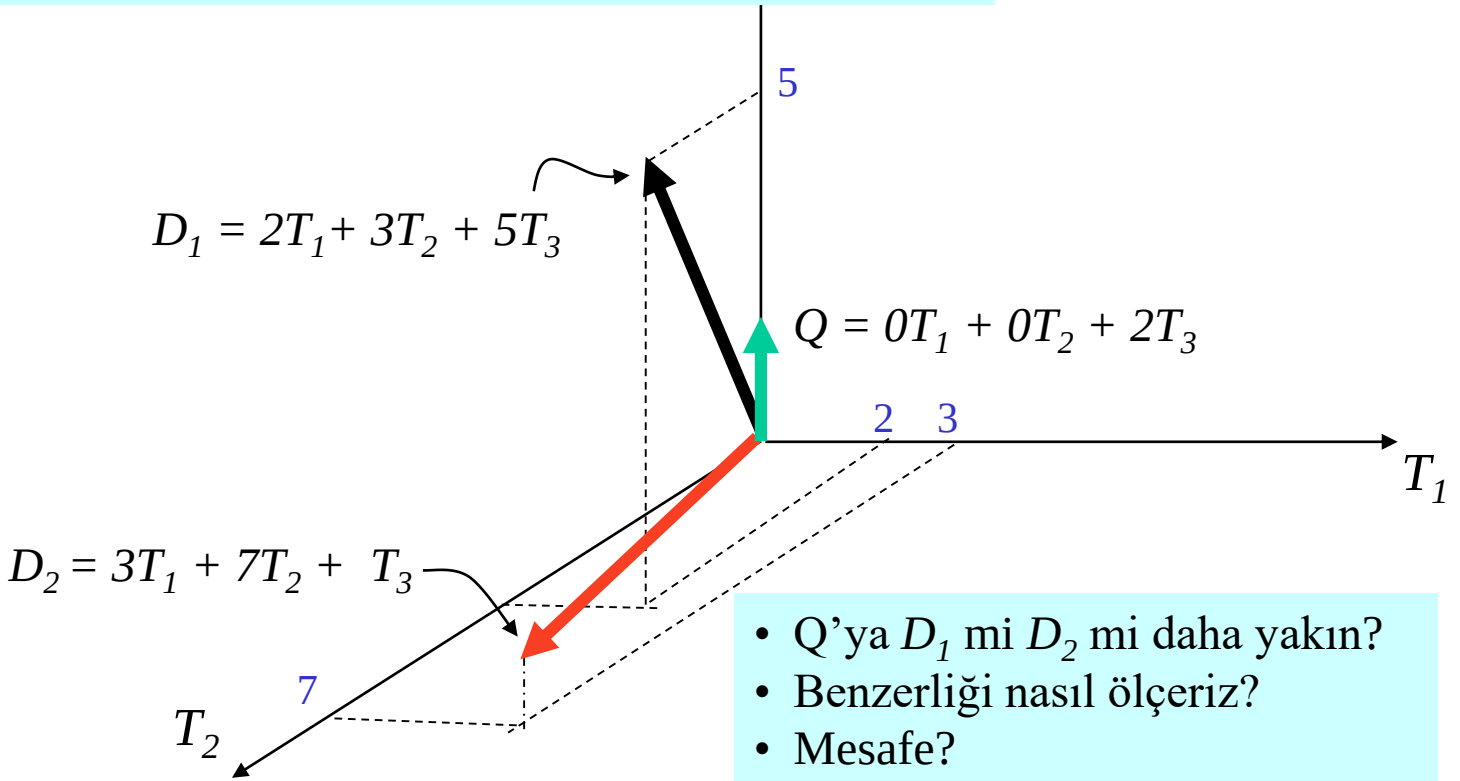

- Q'ya D_1 mi D_2 mi daha yakın?
- Benzerliği nasıl ölçeriz?
- Mesafe?
- Açı?
- Projeksiyon?

Benzerlik Ölçümü- Inner Product

$$\text{sim}(D_i, Q) = \sum_{i=1}^{t} (D_i \bullet Q)$$

$$= \sum_{j=1}^{t} d_{ij} * q_j$$

Inner Product - Örnek

Binary:

	retrieval	database	architecture	computer	text	management	information
– D =	1,	1,	1,	0,	1,	1,	0
– Q =	1,	0 ,	1,	0,	0,	1,	1

→ sim(D, Q) = 3

- Vektör boyutu=Sözlük boyutu=7

Ağırlıklı:

$$D_1 = 2T_1 + 3T_2 + 5T_3$$

$$Q = 0T_1 + 0T_2 + 2T_3$$

$$\text{sim}(D_1, Q) = 2*0 + 3*0 + 5*2 = 10$$

Inverted file index

Metinler

*T*0 = "it is what it is"
*T*1 = "what is it"
*T*2 = "it is a banana“

inverted file index

- "a": {2}
- "banana": {2}
- "is": {0, 1, 2}
- "it": {0, 1, 2}
- "what": {0, 1}

"what", "is" ve "it" kelimeleriyle arama yapılırsa.

$$\{0, 1\} \cap \{0, 1, 2\} \cap \{0, 1, 2\} = \{0, 1\}$$

Full inverted file index: (pozisyonları da içerir)

- "a": {(2, 2)}
- "banana": {(2, 3)}
- "is": {(0, 1), (0, 4), (1, 1), (2, 1)}
- "it": {(0, 0), (0, 3), (1, 2), (2, 0)}
- "what": {(0, 2), (1, 0)}

- Pratikte doküman vektörleri direkt olarak saklanmaz. Hafıza problemlerinden ötürü, arama için aşağıdaki gibi bir yapıda saklanırlar.

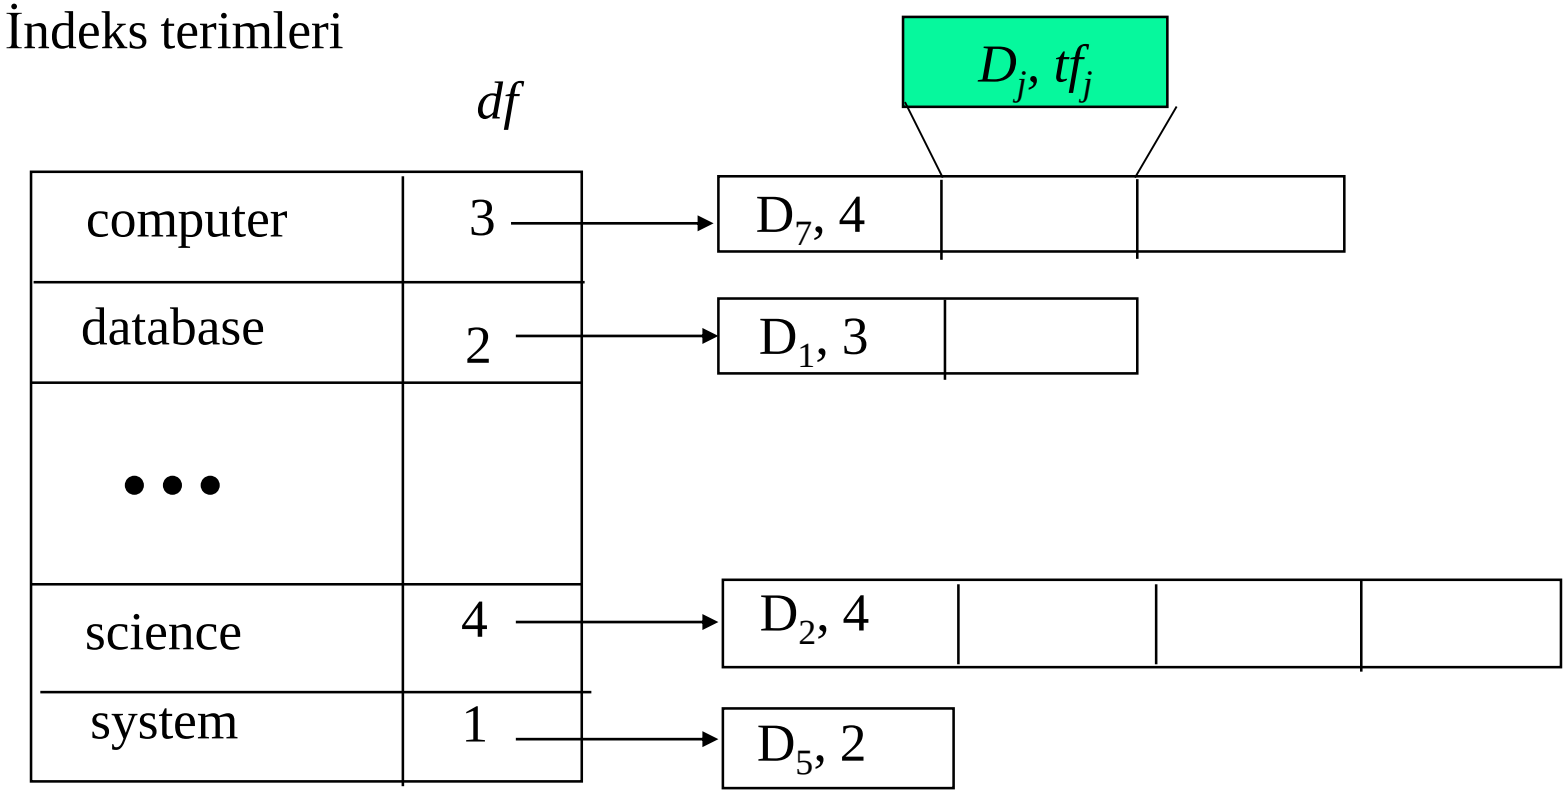

Matemetiksel Modeller

Küme-Kuramsal Modeller (Set-theoretic models)

Dokümanlar kelimeler veya ifadelerin kümesi olarak gösterilir.

En çok bilinen modeller:

- Standard Boolean Model
- Extended Boolean Model
- **Fuzzy Retrieval**

Doğal Dil

- Varsayım:
  - Joe is tall -- what is tall?
  - Joe is very tall -- what does this differ from tall?

- Doğal dil (yaşamdaki ve hatta evrendeki diğer pek çok faaliyet gibi) 0 ve 1'in mutlak terimlerine kolayca çevrilemez.

Bulanık Mantık (Fuzzy Logic)

- Gerçek değerleri [0..1] ve mantık işlemlerini birleştiren bir belirsizlik yaklaşımıdır.
- Bulanık mantık, bulanık küme teorisi ve doğal dilde sıklıkla bulunan bulanık küme üyeliği fikirlerine dayanmaktadır.

Örnek:

- Ann is 28, 0.8 in set "Young"
- Bob is 35, 0.1 in set "Young"
- Charlie is 23, 1.0 in set "Young"

- İstatistik ve olasılıklardan farklı olarak derece, öğenin kümede yer alma olasılığını değil, öğenin ne ölçüde kümede yer aldığını tanımlar.

Bulanık mantık üyelik fonksiyonu

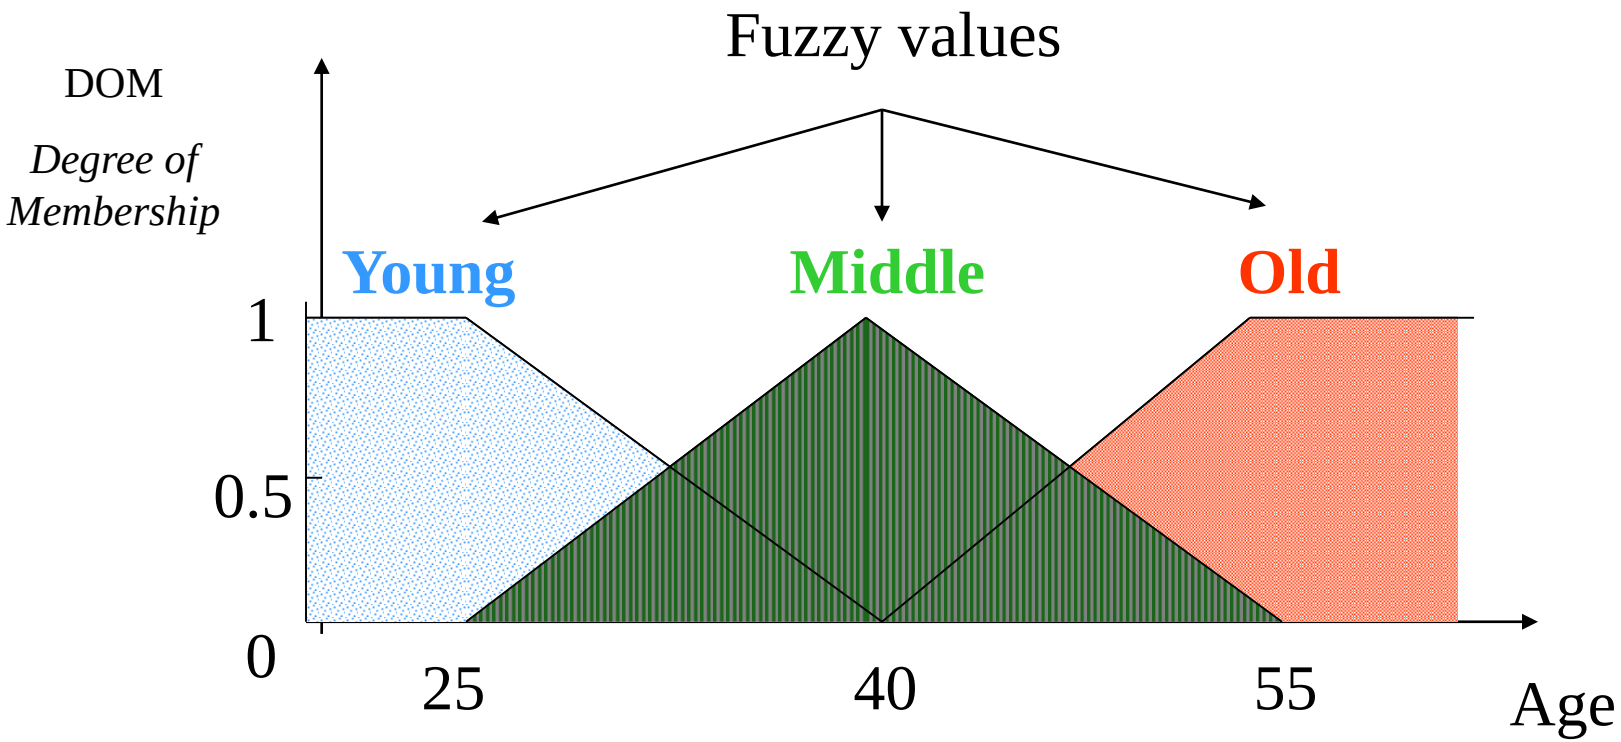

Bulanık değerlerin küme içinde ilişkili üyelik dereceleri vardır.

Fuzzy Küme İşlemleri

Fuzzy OR (∪): İki bulanık kümenin birleşimi, iki kümedeki her bir elemanın maksimumudur (MAX).

$A = \{1.0, 0.20, 0.75\}$

$B = \{0.2, 0.45, 0.50\}$

$A \cup B = \{MAX(1.0, 0.2), MAX(0.20, 0.45), MAX(0.75, 0.50)\}$

$= \{1.0, 0.45, 0.75\}$

Fuzzy AND (∩): İki bulanık kümenin kesişimi, iki kümedeki her bir elemanın minimumudur (MIN).

$A \cap B = \{MIN(1.0, 0.2), MIN(0.20, 0.45), MIN(0.75, 0.50)\}$

$= \{0.2, 0.20, 0.50\}$

Tümleyen (A^C): Bir bulanık kümenin tümleyeni, tüm elemanların tümleyenlerinden oluşur (1-x).

$A^C = \{1 - 1.0, 1 - 0.2, 1 - 0.75\} = \{0.0, 0.8, 0.25\}$

Fuzzy Retrieval

Mix Min Max Model

Bulanık küme teorisinde, bir elemanın değişen bir üyelik derecesi vardır. Örneğin dA

Bulanık küme teorisinde birleşim ve kesişim için üyelik derecesi aşağıdaki gibi tanımlanır.

$$d_{A \cup B} = max(d_A, d_B) \qquad d_{A \cap B} = min(d_A, d_B)$$

MMM modeli, sorgu-doküman benzerliğini **min** ve **max** belge ağırlıklarının doğrusal bir kombinasyonu olarak düşünerek, Boolean operatörlerini yumuşatmaya çalışır.

Verilen doküman *D*, *A1*, *A2*, ..., *An* terimleri için de ağırlandırılmış değerler *dA1*, *dA2*, ..., *dAn* olsun.

Sorgular :
Qor = (A1 or A2 or ... or An)
Qand = (A1 and A2 and ... and An)

MMM modelinde sorgu-doküman benzerliği hesaplanır aşağıdaki gibi hesaplanır:

$$SlM(Qor, D) = Cor1 * max(dA1, dA2, ..., dAn) + Cor2 * min(dA1, dA2, ..., dAn)$$
$$SlM(Qand, D) = Cand1 * min(dA1, dA2, ..., dAn) + Cand2 * max(dA1, dA2 ...,dAn)$$

Cor1, *Cor2*, **or** operatörü için "softness" katsayılarıdır.
Cand1, *Cand2* **and** operatörü için "softness" katsayılarıdır.

Cor1 > Cor2 ve Cand1 > Cand2
Cor1 = 1 - Cor2 ve *Cand1 = 1 - Cand2*

Deneyler, en iyi performansın genellikle aşağıdaki durumlarda ortaya çıktığını göstermektedir.

Cand1 [0.5, 0.8] aralığında ve *Cor1 > 0.2* ile

MMM'nin hesaplama maliyeti düşüktür ve erişim etkinliği Standart Boolean modelinden çok daha iyi.

Matemetiksel Modeller
(Algebraic model)

Cebirsel Modeller dokümanları ve sorguları genellikle vektörler, matrisler veya tuple'lar olarak temsil eder.

Sorgu vektörü ile belge vektörünün benzerliği skaler bir değer olarak temsil edilir.

Latent Semantic Indexing

Gizli Anlam Indeksleme (Latent Semantic Indexing) nedir?

- LSI, doğal dil işlemede dokümanlar ve dokümanların içerdiği terimler arasındaki anlamsal ilişkilerin analizinde kullanılan bir tekniktir.

- Klasik yöntemler, dokümanların aranan terimi içerip içermediğine bakarak sınıflandırır ve bir dokümanın başka bir dokümanla ilişkisini göz önünde bulundurmaz.

- İki doküman, ortak kelimeleri olmasa bile semantik olarak birbirine benzer olabilir.

- LSI doküman setlerini bir bütün olarak değerlendirir ve aranan terimin geçtiği dokümanların yanısıra yakın anlamdaki terimlerin bulunduğu dokümanları da bularak sonuç setini genişletir.

➢LSI matematiksel bir yaklaşım kullanır, kelimelerin anlamlarını çıkarmakla ve kelimeleri analiz etmekle uğraşmaz.

Örnekler:
Associated Press haber veritabanında Saddam Hüseyin için yapılan bir arama sonuç olarak:

• Körfez Savaşı, BM yaptırımı, benzin ambargosu makalelerini ve ayrıca
• Irak hakkında Saddam Hüseyin isminin geçmediği makaleleri de döndürmüştür.

• Aynı veritabanında Tiger Woods için yapılan bir arama sonucu, Ünlü golfçünün pekçok hikayesinin anlatıldığı makalelerin yanısıra Tiger Woods yer almadığı ancak, büyük golf turnuvaları hakkındaki makalelerde döndürülmüştür.

➢LSI, doğal dillerde çokça geçen ve semantik olarak bir anlamı olmayan kelimeleri eler.

➢LSI, sadece semantik olarak bir anlamı olan “content word”ler üzerinde çalışır.

➢ Content word’ler belirlendikten sonra terim doküman matrisi oluşturulur. Yatay eksende content word ler, dikey eksende de dokümanlar bulunur.

➢ Her content word için ilgili satıra gidilir ve o content word’ün geçtiği dokumanların bulunduğu sütunlar 1 olarak değerlendirilir. Kelimenin geçmediği sütunlara ise 0 verilir.

➢ Oluşturulan matrise “Singular Value Decomposition(SVD)” yöntemi uygulanarak matrisin boyutları indirgenir.

LSI için örnek

O'Neill Criticizes Europe on Grants PITTSBURGH (AP)

Treasury Secretary Paul O'Neill expressed irritation Wednesday that European countries have refused to go along with a U.S. proposal to boost the amount of direct grants rich nations offer poor countries.

The Bush administration is pushing a plan to increase the amount of direct grants the World Bank provides the poorest nations to 50 percent of assistance, reducing use of loans to these nations.

Başlıklar, noktalama işaretleri ve büyük harfler kaldırılır.

o'neill criticizes europe on grants treasury secretary paul o'neill expressed irritation wednesday that european countries have refused to go along with a us proposal to boost the amount of direct grants rich nations offer poor countries the bush administration is pushing a plan to increase the amount of direct grants the world bank provides the poorest nations to 50 percent of assistance reducing use of loans to these nations

- Content word’ler ayrılır. Bunun için semantik anlamı olmayan “stop words” kelimeleri çıkarılır.

o'neill criticizes europe grants treasury secretary paul o'neill expressed irritation european countries refused US proposal boost direct grants rich nations poor countries bush administration pushing plan increase amount direct grants world bank poorest nations assistance loans nations

- Çoğul ekleri ve fiil ekleri kaldırılır. İngilizce dili için için Porter Stemmer Algoritması, Türkçe için de Zemberek kullanılabilir.

Content word'ler:

administrat amountassist bank boost bush countri (2) direct europ express grant (2) increas irritat loan nation (3) o'neill paul plan poor (2) propos push refus rich secretar treasuriUS world

- Bu işlem eldeki tüm dokümanlara uygulanır, bir dokümanda ve her dokümanda geçen kelimeleri eleriz ve terim-doküman matrisini elde ederiz.

Term-Document Matris

Document:	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q	r	{3000 more columns}
aa	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...
amotd	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...
aaliyah	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...
aarp	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	...
ab	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...
zywicki	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	...

- Sıfır olmayan her terim-doküman çifti için “terim ağırlığı (term weighting)” değeri bulunur.

1. Bir doküman içinde fazla görünen kelimelerin sadece bir kere görünen kelimelerden daha fazla anlamı vardır.
2. Seyrek kullanılan kelimeler, daha yaygın kullanılan kelimelerden daha ilginç olabilir.

Birincisi her doküman için tek tek uygulanır, buna “yerel ağırlık (local weighting)” denir.

İkincisi bütün dokümanlara birden uygulanır, buna da “global terim ağırlığı (global term weighting)” denir.

- Normalizasyon yapılır.
- Bu üç değer, yani yerel ağırlık, global ağırlık ve normalizasyon faktörü çarpılarak terim-doküman matrisinin sıfır olmayan yerlerinde kullanılacak nümerik değerler bulunur.
- Bundan sonra SVD algoritması çalıştırılır.

	a	b	c	d	e	f	g	h	i	j	k
aa	-0.0006	-0.0006	0.0002	0.0003	0.0001	0.0000	0.0000	-0.0001	0.0007	0.0001	0.0004 ...
amotd	-0.0112	-0.0112	-0.0027	-0.0008	-0.0014	0.0001	-0.0010	0.0004	-0.0010	-0.0015	0.0012 ...
aaliyah	-0.0044	-0.0044	-0.0031	-0.0008	-0.0019	0.0027	0.0004	0.0014	-0.0004	-0.0016	0.0012 ...
aarp	0.0007	0.0007	0.0004	0.0008	-0.0001	-0.0003	0.0005	0.0004	0.0001	0.0025	0.0000 ...
ab	-0.0038	-0.0038	0.0027	0.0024	0.0036	-0.0022	0.0013	-0.0041	0.0010	0.0019	0.0026 ...
zywicki	-0.0057	0.0020	0.0039	-0.0078	-0.0018	0.0017	0.0043	-0.0014	0.0050	-0.0020	-0.0011 ...

Matris daha az sıfır değeri içerir. Her doküman çoğu content word için benzerlik değeri içerir.

- Bazı değerler negatiftir. Bu Terim Doküman Matrisin'de bir kelimenin bir dokümanda sıfırdan daha az sayıda görünmesi demektir. Bu imkansızdır, aslında doküman ile kelimenin semantik olarak birbirlerine çok uzak olduklarına işaret eder.

- Bu matris bizim dokümanlarımızda arama yapmada kullanacağımız matristir. Bir veya daha fazla terim içeren bir sorguda her terim-doküman kombinasyonu için değerlere bakarız ve her doküman için kümülatif bir skor hesaplarız. Bu dokümanların arama sorgusuna olan benzerliklerini ifade eder.

LSI'nın Kullanım Alanları

- Informal Retrieval
- Synonymy (eş anlamlı)
- Polysemy (yazılışı aynı anlamı farklı)
- Arşivleme
- Otomatik Doküman Sınıflandırma
- Doküman Özetleme
- Metinsel Tutarlık Hesaplama
- Bilgi Filtreleme
- Teknik Raporların Benzerliği
- Yazar Tanıma
- Görüntü dosyalarının otomatik olarak anahtar bir kelime ile işaretlenmesi

Singular Value Decomposition (SVD)

Problem: Compute the full SVD for the following matrix:

$$A = \begin{bmatrix} 4 & 0 \\ 3 & -5 \end{bmatrix}$$

Step 1. Compute its transpose $\mathbf{A^T}$ and $\mathbf{A^TA}$.

Since $A^T = \begin{bmatrix} 4 & 3 \\ 0 & -5 \end{bmatrix}$ then, $A^TA = \begin{bmatrix} 4 & 3 \\ 0 & -5 \end{bmatrix} \begin{bmatrix} 4 & 0 \\ 3 & -5 \end{bmatrix}$

$$A^TA = \begin{bmatrix} 25 & -15 \\ -15 & 25 \end{bmatrix}$$

Step 2. Determine the eigenvalues of $\mathbf{A^TA}$ and sort these in descending order, in the absolute sense. Square roots these to obtain the singular values of **A**.

$$A^TA - cI = \begin{bmatrix} 25 - c & -15 \\ -15 & 25 - c \end{bmatrix} \qquad |A^TA - cI| = (25 - c)(25 - c) - (-15)(-15) = 0$$

characteristic equation $\longrightarrow$ $c^2 - 50c + 400 = 0$

The quadratic equation gives two values.
In decreasing order, these are $\longrightarrow$ $|40| > |10|$

eigenvalues $\longrightarrow$ $c_1 = 40 \quad c_2 = 10$

singular values $\longrightarrow$ $s_1 = \sqrt{40} = 6.3245 > s_2 = \sqrt{10} = 3.1622$

Step 3. Construct diagonal matrix S by placing singular values in descending order along its diagonal. Compute its inverse, S^{-1}.

$$S = \begin{bmatrix} 6.3245 & 0 \\ 0 & 3.1622 \end{bmatrix} \qquad S^{-1} = \begin{bmatrix} 0.1581 & 0 \\ 0 & 0.3162 \end{bmatrix}$$

Step 4. Use the ordered eigenvalues from step 2 and compute the eigenvectors of A^TA. Place these eigenvectors along the columns of V and compute its transpose, V^T.

for $c_1 = 40$

$$A^TA - cI = \begin{bmatrix} 25 - 40 & -15 \\ -15 & 25 - 40 \end{bmatrix} = \begin{bmatrix} -15 & -15 \\ -15 & -15 \end{bmatrix}$$

$$(A^TA - cI)\, x_1 = 0$$

$$\begin{bmatrix} -15 & -15 \\ -15 & -15 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$-15 x_1 + -15 x_2 = 0$$
$$-15 x_1 + -15 x_2 = 0$$

Solving for x_2 for either equation: $x_2 = -x_1$

$$X_1 = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} x_1 \\ -x_1 \end{bmatrix}$$

Dividing by its length,

$$L = \sqrt{x_1^2 + x_2^2} = x_1\sqrt{2}$$

$$X_1 = \begin{bmatrix} x_1 / L \\ -x_1 / L \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{-1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 0.7071 \\ -0.7071 \end{bmatrix}$$

for $c_2 = 10$

$$A^TA - cI = \begin{bmatrix} 25 - 10 & -15 \\ -15 & 25 - 10 \end{bmatrix} = \begin{bmatrix} 15 & -15 \\ -15 & 15 \end{bmatrix}$$

$$(A^TA - cI)\, x_2 = 0$$

$$\begin{bmatrix} 15 & -15 \\ -15 & 15 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$15 x_1 + -15 x_2 = 0$$
$$-15 x_1 + 15 x_2 = 0$$

Solving for x_2 for either equation: $x_2 = x_1$

$$X_2 = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} x_1 \\ x_1 \end{bmatrix}$$

Dividing by its length,

$$L = \sqrt{x_1^2 + x_2^2} = x_1\sqrt{2}$$

$$X_2 = \begin{bmatrix} x_1 / L \\ x_1 / L \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix} = \begin{bmatrix} 0.7071 \\ 0.7071 \end{bmatrix}$$

$$V = \begin{bmatrix} x_1 & x_2 \end{bmatrix} = \begin{bmatrix} 0.7071 & 0.7071 \\ -0.7071 & 0.7071 \end{bmatrix}$$

$$V^T = \begin{bmatrix} 0.7071 & -0.7071 \\ 0.7071 & 0.7071 \end{bmatrix}$$

Step 5. Compute U as $U = AVS^{-1}$. To complete the proof, compute the full SVD using $A = USV^T$.

$$U = AVS^{-1} = \begin{bmatrix} 4 & 0 \\ 3 & -5 \end{bmatrix} \begin{bmatrix} 0.7071 & 0.7071 \\ -0.7071 & 0.7071 \end{bmatrix} \begin{bmatrix} 0.1581 & 0 \\ 0 & 0.3162 \end{bmatrix}$$

$$U = AVS^{-1} = \begin{bmatrix} 4 & 0 \\ 3 & -5 \end{bmatrix} \begin{bmatrix} 0.1118 & 0.2236 \\ -0.1118 & 0.2236 \end{bmatrix}$$

$$U = AVS^{-1} = \begin{bmatrix} 0.4472 & 0.8944 \\ 0.8944 & -0.4472 \end{bmatrix}$$

$$A = USV^T = \begin{bmatrix} 0.4472 & 0.8944 \\ 0.8944 & -0.4472 \end{bmatrix} \begin{bmatrix} 6.3245 & 0 \\ 0 & 3.1622 \end{bmatrix} \begin{bmatrix} 0.7071 & -0.7071 \\ 0.7071 & 0.7071 \end{bmatrix}$$

$$A = USV^T = \begin{bmatrix} 0.4472 & 0.8944 \\ 0.8944 & -0.4472 \end{bmatrix} \begin{bmatrix} 4.4721 & -4.4721 \\ 2.2360 & 2.2360 \end{bmatrix}$$

$$A = USV^T = \begin{bmatrix} 3.9998 & 0 \\ 2.9999 & -4.9997 \end{bmatrix} \approx \begin{bmatrix} 4 & 0 \\ 3 & -5 \end{bmatrix}$$

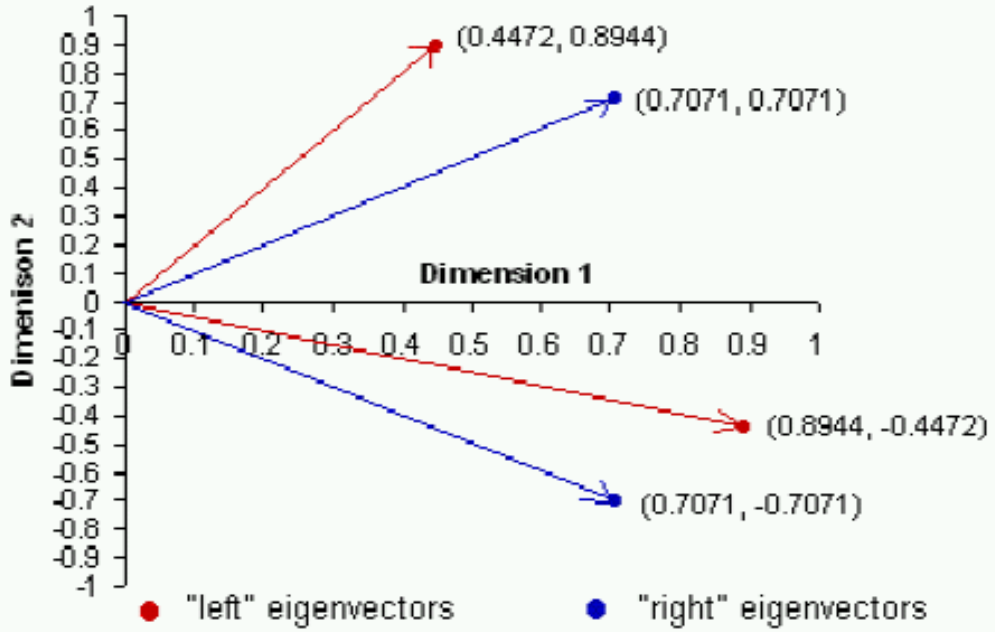

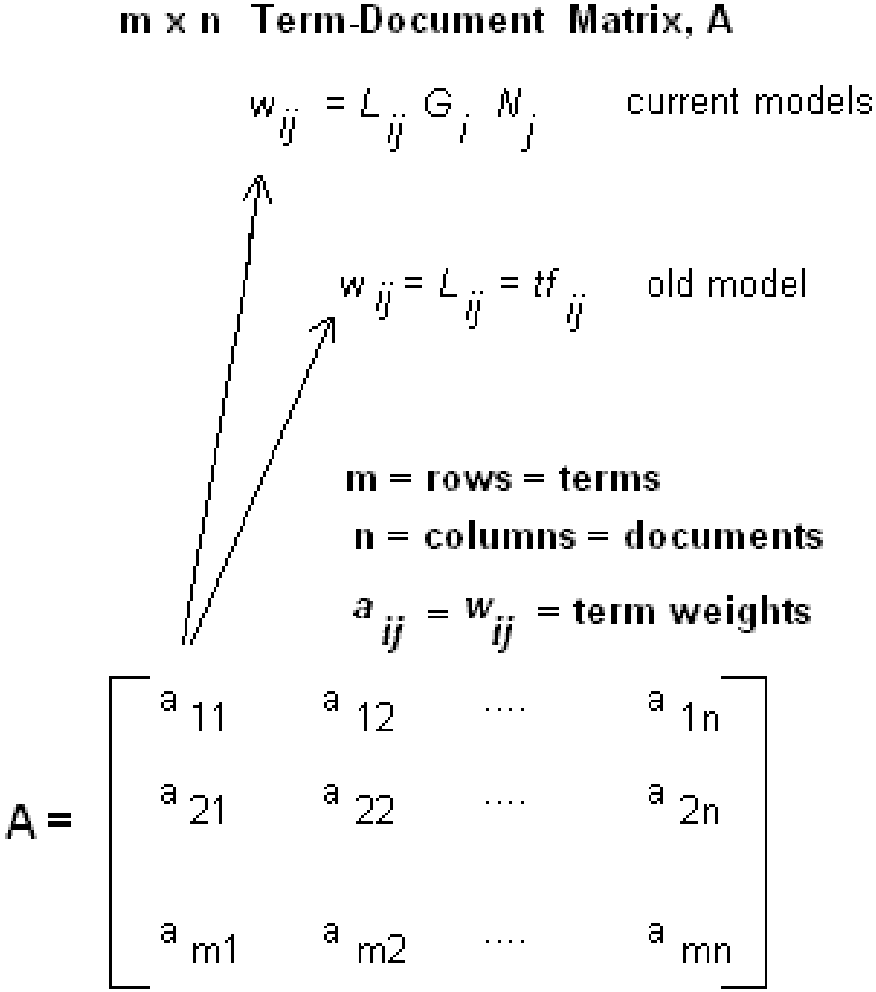

Term Count Model

The weight of term i in document j is defined as a local weight (*Lij*):

Equation 1: *wij = Lij = tfij*

where *tfij* is term frequency or number of times term i occurs in document j.

Equation 2: *wij = LijGiNj*

where *Li, j* is the local weight for term *i* in document *j*.

Gi is the global weight for term *i* across all documents in the collection.

Nj is the normalization factor for document *j*.

Latent Semantic Indexing (LSI)

A “collection” consists of the following “documents”

d1: Shipment of gold damaged in a fire.
d2: Delivery of silver arrived in a silver truck.
d3: Shipment of gold arrived in a truck.

The authors used the Term Count Model to score term weights and query weights, so local weights aredefined as word occurences. The following document indexing rules were also used:

· stop words were not ignored
· text was tokenized and lowercased
· no stemming was used
· terms were sorted alphabetically

Problem: Use Latent Semantic Indexing (LSI) to rank these documents for the query *gold silver truck*.

Step 1: Score term weights and construct the term-document matrix **A** and query matrix:

Terms	d1	d2	d3	q
a	1	1	1	0
arrived	0	1	1	0
damaged	1	0	0	0
delivery	0	1	0	0
fire	1	0	0	0
gold	1	0	1	1
in	1	1	1	0
of	1	1	1	0
shipment	1	0	1	0
silver	0	2	0	1
truck	0	1	1	1

$A =$ (the d1, d2, d3 columns) $\quad q =$ (the q column)

Step 2: Decompose matrix **A** matrix and find the **U**, **S** and **V** matrices, where

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^{\mathbf{T}}$$

$$\mathbf{U} = \begin{bmatrix} -0.4201 & 0.0748 & -0.0460 \\ -0.2995 & -0.2001 & 0.4078 \\ -0.1206 & 0.2749 & -0.4538 \\ -0.1576 & -0.3046 & -0.2006 \\ -0.1206 & 0.2749 & -0.4538 \\ -0.2626 & 0.3794 & 0.1547 \\ -0.4201 & 0.0748 & -0.0460 \\ -0.4201 & 0.0748 & -0.0460 \\ -0.2626 & 0.3794 & 0.1547 \\ -0.3151 & -0.6093 & -0.4013 \\ -0.2995 & -0.2001 & 0.4078 \end{bmatrix} \quad \mathbf{S} = \begin{bmatrix} 4.0989 & 0.0000 & 0.0000 \\ 0.0000 & 2.3616 & 0.0000 \\ 0.0000 & 0.0000 & 1.2737 \end{bmatrix}$$

$$\mathbf{V} = \begin{bmatrix} -0.4945 & 0.6492 & -0.5780 \\ -0.6458 & -0.7194 & -0.2556 \\ -0.5817 & 0.2469 & 0.7750 \end{bmatrix} \quad \mathbf{V}^{\mathbf{T}} = \begin{bmatrix} -0.4945 & -0.6458 & -0.5817 \\ 0.6492 & -0.7194 & 0.2469 \\ -0.5780 & -0.2556 & 0.7750 \end{bmatrix}$$

Step 3: Implement a Rank 2 Approximation by keeping the first columns of **U** and **V** and the first columns and rows of **S**.

$$k = 2$$

$$U \approx U_k = \begin{bmatrix} -0.4201 & 0.0748 \\ -0.2995 & -0.2001 \\ -0.1206 & 0.2749 \\ -0.1576 & -0.3046 \\ -0.1206 & 0.2749 \\ -0.2626 & 0.3794 \\ -0.4201 & 0.0748 \\ -0.4201 & 0.0748 \\ -0.2626 & 0.3794 \\ -0.3151 & -0.6093 \\ -0.2995 & -0.2001 \end{bmatrix} \qquad S \approx S_k = \begin{bmatrix} 4.0989 & 0.0000 \\ 0.0000 & 2.3616 \end{bmatrix}$$

$$V \approx V_k = \begin{bmatrix} -0.4945 & 0.6492 \\ -0.6458 & -0.7194 \\ -0.5817 & 0.2469 \end{bmatrix} \qquad V^T \approx V_k^T = \begin{bmatrix} -0.4945 & -0.6458 & -0.5817 \\ 0.6492 & -0.7194 & 0.2469 \end{bmatrix}$$

Step 4: Find the new document vector coordinates in this reduced 2-dimensional space.
Rows of **V** holds eigenvector values. These are the coordinates of individual document vectors, hence

d1(-0.4945, 0.6492)
d2(-0.6458, -0.7194)
d3(-0.5817, 0.2469)

Step 5: Find the new query vector coordinates in the reduced 2-dimensional space.

$$\mathbf{q} = \mathbf{q}^{T}\mathbf{U}_{k}\mathbf{S}_{k}^{-1}$$

$$q = q^T U_k S_k^{-1} \qquad k = 2$$

$$q = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 1 \end{bmatrix} \begin{bmatrix} -0.4201 & 0.0748 \\ -0.2995 & -0.2001 \\ -0.1206 & 0.2749 \\ -0.1576 & -0.3046 \\ -0.1206 & 0.2749 \\ -0.2626 & 0.3794 \\ -0.4201 & 0.0748 \\ -0.4201 & 0.0748 \\ -0.2626 & 0.3794 \\ -0.3151 & -0.6093 \\ -0.2995 & -0.2001 \end{bmatrix} \begin{bmatrix} \frac{1}{4.0989} & 0.0000 \\ 0.0000 & \frac{1}{2.3616} \end{bmatrix}$$

$$q = \begin{bmatrix} -0.2140 & -0.1821 \end{bmatrix}$$

Step 6: Rank documents in decreasing order of query-document cosine similarities.

$$sim(q, d) = \frac{q \bullet d}{|q||d|}$$

$$sim(q, d_1) = \frac{(-0.2140)(-0.4945) + (-0.1821)(0.6492)}{\sqrt{(-0.2140)^2 + (-0.1821)^2}\sqrt{(-0.4945)^2 + (0.6492)^2}} = -0.0541$$

$$sim(q, d_2) = \frac{(-0.2140)(-0.6458) + (-0.1821)(-0.7194)}{\sqrt{(-0.2140)^2 + (-0.1821)^2}\sqrt{(-0.6458)^2 + (-0.7194)^2}} = 0.9910$$

$$sim(q, d_3) = \frac{(-0.2140)(-0.5817) + (-0.1821)(0.2469)}{\sqrt{(-0.2140)^2 + (-0.1821)^2}\sqrt{(-0.5817)^2 + (0.2469)^2}} = 0.4478$$

Ranking documents in descending order

$$d_2 > d_3 > d_1$$

We can see that document d2 scores higher than d3 and d1. Its vector is closer to the query vector than the other vectors. Also note that Term Vector Theory is still used at the beginning and at the end of LSI.

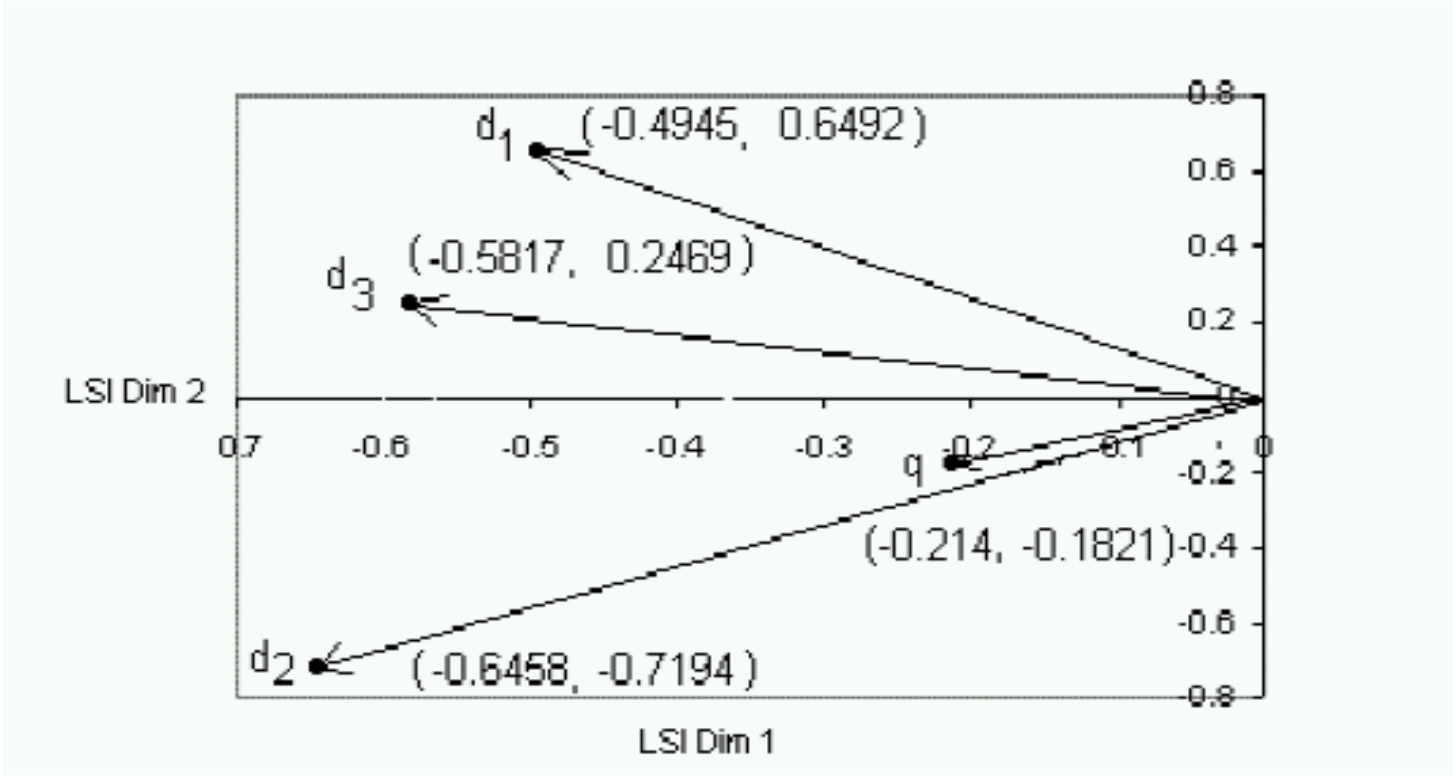

Arama Motorları

Arama motorlarının temeli geleneksel bilgi erişim sistemleri mimarisine dayanmakla birlikte, gerek mimari gerek işlevsel açıdan bazı farklılıklar içermektedir.

Arama motorları temel olarak 3 ana bileşenden oluşur:

- Web örümceği (crawler) bileşeni
- Dizinleme (indexing) bileşeni
- Arama (search) bileşeni

Bilgi erişim sistemlerinde dizinlenecek belgeler durağandır (statik). Başka bir deyişle, bir belge bir defa dizinlendikten sonra bir daha dizinleme işlemine tabi tutulmaz.

Diğer taraftan, Web kaynakları tahmini olarak ortalama 75 gün değişmeden kalmaktadırlar (Brake, 2001)
Internet ortamındaki bir bağlantının (link) ortalama ömrünün 44 gün olduğunu belirtmektedir (Kahle, 1997)
Bir Web sitesinin "yarı ömrü"nün (half-life) iki yıl civarında olduğu söylenmektedir.

Bu tür bilgiler, arama motorlarının mimarisinin bilgi erişim sistemlerininkine göre farklı olmasını gerektirmektedir. Çünkü çok daha dinamik bir yapıya sahiptirler.

Google'ın Mimarisi

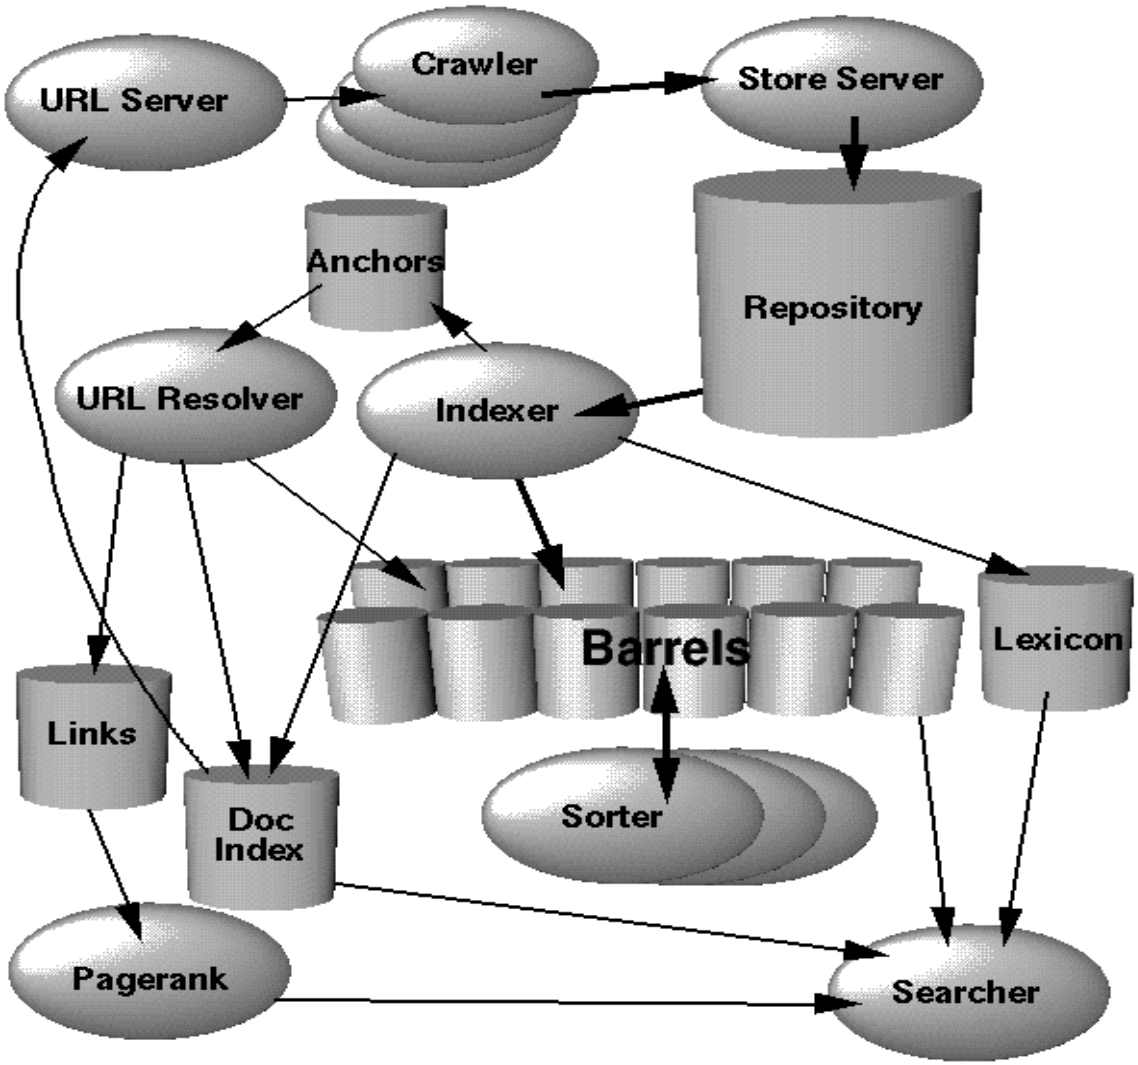

Kaynak: BRIN & PAGE

- URL Server- kaydedilecek URL'ler
- Crawler paralel
- Store Server – crawler'lardan gelen sayfaları sıkıştırıp repository'e kaydeder.
- Repository – sayfaların HTML kodları
- Indexer – forward barrel'leri ve anchors'u oluşturur.
- Lexicon – tekil kelime listesi, yer aldığı docID'ler
- Barrels (docID, (wordID, hitList*)*)* ler
- Anchors – sayfalarda bulunan link bilgileri (from, to, anchor text)
- URL Resolver – Anchors'daki rölatif URL'leri gerçek URL'lere dönüştürür. DocID'lerini verir. Links'i oluşturur. Anchor metinlerini forward barrel'lara ekler
- Sorter – inverted barrel'leri oluşturur.
- Doc Index – her sayfa hakındaki bilgiler (durum, repository'deki pointer vs.)
- Links – docID ikilileri
- Pagerank – her sonuç sayfasının önemini, popülerliğini (links'ten) hesaplar
- Searcher – sorguları cevaplar

Arama Sonuçlarının Derecelendirilmesi

-Pek çok arama motoru erişim fonksiyonu (vektör uzayı, olasılıksal, dil modeli v.b.) olarak kullanılan yöntemlerin doküman/sorgu eşleşmesi için ürettiği skor değerlerine göre bir derecelendirme yapar.

-Google ile birlikte bu derecelendirme skoruna link alma skorları da eklenmiştir.

-PageRank (Sayfa Derecelendirme) yöntemi, Internet üzerinde bir sayfaya diğer sayfalardan ne kadar fazla referans (link) verilirse o sayfanın o kadar değerli olacağı görüşü üzerine geliştirilmiştir.

- Bu yaklaşım "bilimsel bir çalışmaya diğer makalelerden ne kadar çok atıfta bulunulursa o çalışma o kadar önemlidir" mantığına benzemektedir.

Page Rank'in ana fikri şöyledir:

- Eğer bir A sitesi B sitesinin linkini yayınlamışsa bunun nedeni B sayfasının A sayfası ziyaretçileri tarafından gezilecek olarak düşünülmüş olmasıdır. Bu yapıya göre A sayfası, B sayfasının pagerankini yükseltmiş olacaktır.

- A sayfası ne kadar yüksek pageranke sahipse, B sayfasının pagerank değeri de buna orantılı olarak artacaktır.

-A sayfasında ne kadar az dışarı link varsa, B sayfasının pagerank değeri o kadar yüksek olacaktır. Bu mantığa göre A sayfası sadece B sayfasını link verilecek değerde görmüşse, B sayfasının pageranki çok daha fazla artacaktır.

Örnek

-Elimizde A, B, C ve D sayfalarından oluşan bir derlem olsun.

- Başlangıçta her bir sayfaya gitme olasılığını eşit kabul edersek her bir sayfanın PageRank değeri 0.25 olur (1/4=0.25)

- Elimizdeki sayfalardan B, C ve D'nin her biri, A sayfasına link vermiş olduğunu kabul edelim.

A için güncellenmiş PageRank değeri:

PR(A)= PR(B)+PR(C)+PR(D) = 0.25+0.25+0.25 = 0.75

- B sayfasının aynı zamanda C sayfasına ve D'nin de diğer tüm sayfalara link verdiğini düşünelim. O halde verilen linklerin ağırlıklarının düşürülmesi gerekir ki bu da sayfanın başlangıçtaki PageRank değerinin verilen toplam link sayısına bölünmesi ile elde edilir.

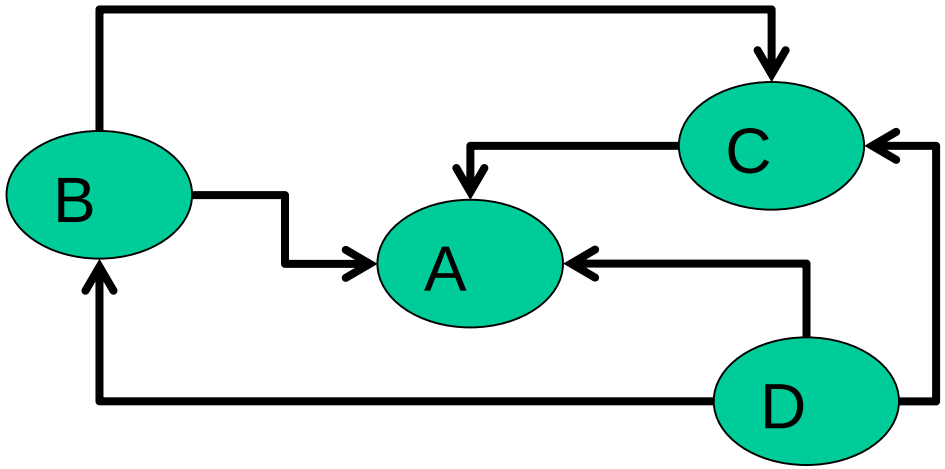

O halde A sayfası için yeni PageRank değeri aşağıdaki gibi hesaplanır:

PR(A) = (PR(B)/2)+(PR(C)/1)+(PR(D)/3)=0,125+0,25+0,083=0,458

Anahtar Kelime Problemleri

- Eşanlamlı kelimeleri içeren dokümanlar bulunamaz.
  - "restaurant" vs. "cafe"
  - "PRC" vs. "China"
- Eşsesli kelimeler ilgisiz dokümanların bulunmasına sebep olabilir.
  - "bat" (baseball, mammal)
  - "Apple" (company, fruit)
  - "bit" (unit of data, act of eating)

Google BERT kullanımı ile bu problemlere büyük oranda çözüm getirilmiştir.

Zeki IR Teknikleri

- Kelimelerin anlamları
- Sorgudaki kelimelerin sırası
- Kullanıcılardan döndürülen sonuçların kalitesiyle ilgili alınan geri bildirimler
- Aramayı ilgili kelimelerle genişletmek
- İmla denetimi
- Kaynakların güvenilirliği

Sensitivity ve Specificity

- İstatistiksel olarak performans ölçüm metrikleridir (Binary Classification).
- **Sensitivity** , bazı alanlarda **Recall** olarak adlandırılır (IR)

Tanım

Bir hastalığın teşhisi için insanlara bir test yapılacağını düşünün.
Test sonucunda kişiler hasta veya değil diye etiketlenecek.
Test sonucu pozitif ise kişi hasta, negatif ise hasta değil demektir.

True positive: Sick people correctly diagnosed as sick
False positive: Healthy people incorrectly identified as sick
True negative: Healthy people correctly identified as healthy
False negative: Sick people incorrectly identified as healthy.

Detection dog

Köpek 1 : Sadece cocaine bulmak için eğitilmiş.

Köpek 2: Cocaine, heroin ve arijuana gibi farklı kokuları almak için eğitilmiş.

Specificity : Birinci köpek, cocaine kaçırmaz ve hatalı tanıma yapma olasılığı azdır

(so it is very *specific).*

Sensitivity : İkinci köpek daha fazla sayıda maddeyi tanır. Fakat cocaine karşı daha az duyarlıdır. Hata yapma olasılığı daha fazladır.

$$\text{specificity} = \frac{\text{number of True Negatives}}{\text{number of True Negatives} + \text{number of False Positives}}$$

$$\text{sensitivity} = \frac{\text{number of True Positives}}{\text{number of True Positives} + \text{number of False Negatives}}$$

		Condition (as determined by “Gold standard")		
		Positive	***Negative***	
Test outcome	***Positive***	**True Positive**	**False Positive** (Type I error, P-value)	Positive predictive value
	Negative	**False Negative** (**Type II error**)	**True Negative**	Negative predictive value
		↓ **Sensitivity**	↓ **Specificity**	

Sensitivity=True Positive Rate=TP/(TP+FN)
Specificity=True Negative Rate=TN/(TN+FP)

False Negative Rate(β)=1-Sensitivity=FN/(TP+FN)
False Positive Rate(α)=1-Specificity=FP/(FP+TN)

Positive Predictive Rate Value=TP/(TP+FP)
Negative Predictive Rate Value=TN/(TN+FN)

Değerlendirme

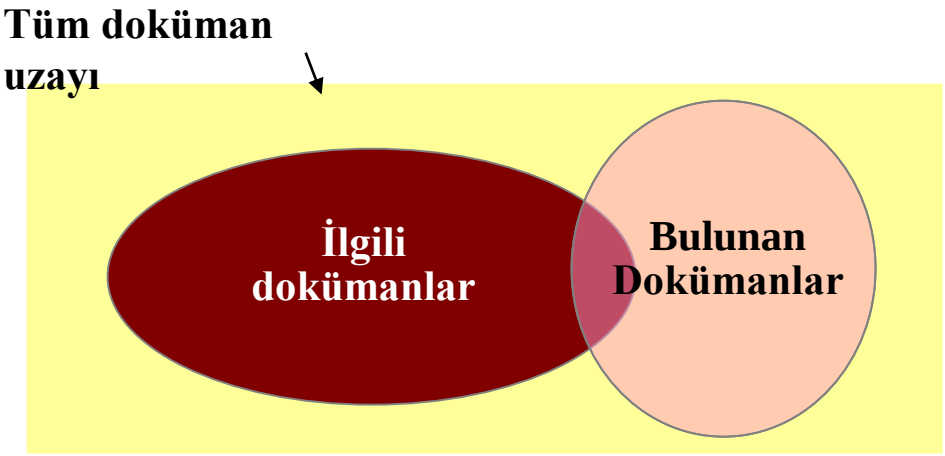

	retrieved	not retrieved
relevant	retrieved & relevant	not retrieved but relevant
irrelevant	retrieved & irrelevant	Not retrieved & irrelevant

F-measure , Precision ve Recall ‘ın harmonik ortalamasıdır.

$$F = 2 \times \frac{\mathbf{precision} \times \mathbf{recall}}{\mathbf{precision} + \mathbf{recall}}$$

Information Retrevial kullanımı

$$\text{precision} = \frac{|\{\text{relevant documents}\} \cap \{\text{retrieved documents}\}|}{|\{\text{retrieved documents}\}|}$$

$$\text{recall} = \frac{|\{\text{relevant documents}\} \cap \{\text{retrieved documents}\}|}{|\{\text{relevant documents}\}|}$$

Kaynaklar

- http://www.cs.huji.ac.il/~sdbi/2000/google/index.htm
- Searching the Web ,Ray Larson & Warren Sack
- Knowledge Management with Documents, Qiang Yang
- Introduction to Information Retrieval, Rada Mihalcea
- Introduction to Information Retrieval, Evren Ermis
- The Anatomy of a Large-Scale Hypertextual Web Search Engine, Sergey Brin, Lawrence Page (http://infolab.stanford.edu/~backrub/google.html)
- http://en.wikipedia.org/wiki/Fuzzy_retrieval

Son