

10-1 التعريف العام لل IR و معرفة مكوناته الأساسية (الندرج بالمكونات لنصل إلى كافة تفاصيله)

35-11 طرق النمذجة للوثائق والاستعلامات (Boolean & Extented boolean & Vector) لكي نستطيع مطابقتها (indexing principle)

55-36 عملية tokenization وذكر حالات شاذة للكلمات، اخراج relevant للوثائق، التحدث عن ال tf-idf مع حساب الأوزان

78-56 DCG و user oriented precision(AP) و Ranked P&C و Average precision(AP) و P&R:evaluation

100-79 تلخيص موجز لvector (تعريفه نتائجه مشاكله)، تجزيء المصفوفة(SVD) semantic hashing, LDI, PLSI, LSI,

113-101 النموذج الإحتمالي، معرفة الإحتمالات الواجب حسابها، طريقة النمذجة logic model, Bayesian network, BM25, BIM

132-114 نمذجة صفحات الويب (crawlers) (تعريفه، بنائه، آلية عمله، محاسنه)

149-133 مناقشة تحديات ال multimedia السبعة وذكر طرق حلها، وذكر مجالات ال IR بالصوت والصور والفيديو والموسيقى

160-150 probabilistic model, vector space(rocchio), Relevance feedback, personalization

1-ص1	ماذا نحتاج من متطلبات لبناء نظام IR يجب على استعلامات؟ داتابيز فقط، معلومات عن المستخدم، نمذجة للوثائق
1-ص2	أنماط الإستعلامات في ال IR؟ Data retrieval, Text search, information retrieval
1-ص3	تعريف نظام ال IR؟ تعريف نظامي له، أمثلة عنه (email, web search, file search, etc)
2-ص4	(query, match, information) للتعبير عن ال IR؟ (smallest picture)
2-ص5	index function (smaller picture) للتعبير عن ال IR؟ نفس مسبق بالإضافة ل index&model ،تعريف retrieval model (small picture) للتعبير عن ال IR؟ نفس مسبق بالإضافة ل Rank ، هدف ال IR مكونات
2-ص6	retrieval model (picture) للتعبير عن ال IR؟ نفس ما سبق بالإضافة ل Language processing ليفهم النظام استعلام المستخدم
2-ص7	(Big picture) للتعبير عن ال IR؟ نفس ما سبق بالإضافة ل UI for complex query, multimedia data
3-ص8	المصطلح ال IR = corpus + model
3-ص9	(Bigger picture) للتعبير عن ال IR؟نفس ما سبق بالإضافة ل expansion , user context, Relevance feedback for rerank
4-ص10	(Biggest picture) للتعبير عن ال IR؟نفس ما سبق بالإضافة ل meta search, IR evaluation
4-ص11	هدف ال IR العام؟ وما هي مشاكله؟ استعادة الوثائق الموافقة للمستخدم وترتيبها بشكل منطقي، مشكلة: لا نعرف ال user need لذلك يبدأ ال IR من الاستعلام لإستعادة النتائج
4-ص12	تعريف ال corpus؟ تجميعية من الوثائق التي يحتاجه المستخدم
4-ص13	ما هو ال index؟ مثال لمكتبة هاري بوتر مفهرسة، وهو طريقة لزيادة سرعة النظام باستعادة المعلومات حيث نبحث أولاً بالفهرس عن مكان جواب الاستعلام م نذهب إليها في ال corpus
4-ص14	ما هو ال index function؟ تابع دخله الوثيقة وخرجه الوثيقة بالفهرس
4-ص15	تعريف ال index terms؟ طرق توليدتها؟ هي كلمات عبارة عن مؤشرات إلى وثائق ال corpus لها تعريفين: index term أو index by subject، طرق التوليد: controlled (شكل يدوي) أو open (شكل أوتوماتيكي)
5-ص16	ما هي طرق آليات بناء الفهرس؟ exhaustively: بناءه قبل معرفة الوثائق، specificity: بناءه بناء على وثائق النظام
5-ص17	الفرق بين ال corpus والفهرس؟ الفهرس يحوي ضياع بالمعلومات ولكن مفيد لزيادة الأداء وبالنهاية تجلب المعلومات من ال corpus
5-ص18	فائدة نمذجة ال query and corpus؟ لزيادة الأداء وعادة يتم نمذجتها بنفس الطريقة من أجل عملية المطابقة
5-ص19	تعريف ال matching؟ طريقة لتطابق الاستعلام مع الفهرس لإستعادة البيانات التي يريدها المستخدم
5-ص20	مثال عن عملية الفهرسة في ال Boolean mode؟ روايات شكسبير، وتوضيح عمليات النمذجة والمطابقة فيه
5-ص21	تعريف Boolean model؟ وما هي مشاكله؟ تعريفه مكتوب نظامي له مشاكل عدّة أهمها لا يوجد Ranking
6-ص22	كيف نستطيع تقليل مشاكل ال Boolean model؟ باستخدام posting list(inverted list) وذكر خوارزمية مطابقتة
6-ص23	تعريف ال BOW
6-ص24	تعريف ال Feast, Famine؟ أحد مشاكل ال Boolean model يا برجع كتير وثائق يا مابرجع شي
6-ص25	أهمية ال Ranking؟ ذكر إحصائية غوغل التي تقول أن الأشخاص فقط يهتمون بأول ثلاثة نتائج
6-ص26	تعريف ال Relevance؟ ذكر أنواعه؟ تعريف نظامي له وذكر قيمته في ال system and user, Boolean model
7-ص27	حل مشكلة ال Ranking في Boolean mode في Ranking (0,1) لذلك يجب أن نجعل قيم مصفوفته أرقام
7-ص28	تعريف ال vector؟ تمثيل الوثائق والاستعلامات كأشعة، قانون المطابقة cos، تذكير بالقانون، تطبيق مثال عليه
7-ص29	تعريف ال document similarity؟ إيجاد طريقة لتجميع الوثائق المشابهة مع بعضها، نستطيع ذلك بنمذجين ال cos وال Boolean vector عن طريق العمليات المنطقية وال cos

بعض مصطلحات ال hard vs soft, flat vs hierarchy, tagging vs statistical ?clustering	7-ص30
ملاحظات عن الcos في المطابقة؟المنفذة دوماً نقص معلومات,المطابقة تتم على المنفذة للوثائق وليس الوثائق نفسها	8-ص31
كيف نميز بين ال and وال or في ال vector؟لا فرق بينهما لأن الشعاع له تمثيل ثابت,يمكن أن نضع وزن للتفريق	8-ص32
ما ال extended boolean لحل مشكلة ال Boolean له حل؟ranking-إضافة عمليات منطقية	8-ص33
جديدة لها درجات مطابقة معينة-2-القيام بمنفذة الوثائق مثل ال vector مع صورة توضح عملية ال And وال or فيه	8-ص34
أسوأ طريقة لإنشاء فهرس للوثائق؟أخذ كل كلمات الوثيقة ك index terms, نضع في الفهرس تكرار كل كلمة بالوثيقة المقتصد بمنفذة الوثائق والإستعلامات؟تمثيلها بشكل معين(أشعة مثلاً) لنتمكن من تطبيق عمليات مطابقة عليها	8-ص35
ما هو inverted index(simple index)؟أخذ كل كلمات ال corpus لتمثيل الوثائق	8-ص36
تعريف ال word,term,token,index term	8-ص37
تعريف عملية ال tokenization؟تقسيم النص إلى token	9-ص38
تعريف vocabulary؟كيف يتم تمثيل الوثائق بعد التقسيم؟كيف نطبقها مع ال query	9-ص39
ذكر أمثلة عن صعوبة عملية ال tokenization من خلال أمثلة (state-of-the-art, database,dates)	9-ص40
ما هو Delimiter الذي يقطع النص على أساسه؟لا يوجد شيء محدد بسبب وجود كلمات شاذة كثيرة	9-ص41
تعريف Relevant Document؟وذكر الفرضيتين الأساسية له؟إيجاد وزن كل index term في الوثيقة,1-ال index term غير الموجود بالوثيقة وزن 0, 2-كل ما تكرر ال index term بالوثيقة زاد وزنه بهذه الوثيقة	9-ص42
مناقشة عدد ال index terms التي نأخذها من أجل كل وثيقة؟هل نأخذها كلها أو نأخذ أكثر عشرة لها وزن بالوثيقة	9-ص43
تعريف Term frequency(tf),Document frequency(df),corpus frequency(cf)	9-ص44
كيف نقوم بحساب وزن كلمة من خلال ال tf؟عبارة عن عامل ضرب ال tf والعامل يحدد علاقة الوزن بال tf	9-ص45
هل نستخدم ال tf مع الإستعلام؟طبعاً لا	10-ص46
مناقشة ال df وتأثيره العكس على الوزن يصبح idf لأنه يتاسب عكساً، ثم وضع القانون العام للوزن بدلاًلة tf,idf	10-ص47
ال tf وال idf ليس لهما مجال معين لذلك نذكر بعض الحيل الرياضية لجعلهما ضمن مجال معين	10-ص48
إيجابيات وسلبيات ال tf-idf؟يتحقق الفرضيين بالسؤال 42، سلبيات صعوبة حسابه، لا نأخذ ترابط الكلمات بعين الاعتبار	10-ص49
حل مشاكل ال lazy calculate, normalize, n-grams, weigh stop word or remove, ontology?tf-idf	10-ص50
صورة توضح عملية tokenization,weight,normalize,index&model?indexing	11-ص51
كيفية عمل ال N-grams؟من أجل $n=4$ نأخذ كلمة ثم اثنين ثم ثلاثة ثم أربع ثم ترجع الكلمات التي تأتي مع بعضها	11-ص52
بعض التحسينات الإضافية على الفهرسة؟هيكلة الوثائق,N-grams,equivelance class,stemming	11-ص53
تعريفات؟hypernyms, hyponyms, synonymous, antonyms	11-ص54
حل أخطاء الكلمات بالإستعلام؟sound, typeset, statistic	11-ص55
توضيح أن عملية الفهرسة والمنفذة قمنا بهما مع بعضهما حيث من الفهرس تم تمثيل كل وثيقة بشعار في فضاء عدد index terms	11-ص56
تعريف نظامي لل evaluation؟هو معايير لنعلم مدى صحة عمل النظام	11-ص57
المعايير التي نقيم النظام بناء عليها؟scalability,online&offline speed,الواجهات,الكلفة,دقة النتائج	11-ص58
كيف نعلم أن النظام يعمل بشكل جيد؟معايير سهل حسابها(سرعة,تكلفة),صعوبة(الدقة),طرق الحساب (1-يدوية مع ذكر مشاكلها-2 user happiness)	12-ص59
ماذا ممكن أن تكون ال user happiness؟سرعة النظام, مجاني, دقة النتائج, الخ	12-ص60
اقتراح طريقة لحساب user happiness؟صعب، نستخدم proxy بالعادة يكون system relevance	12-ص61
تعريف system relevance؟بناء على فرضيتين:1-ما يهم المستخدم هو الإستعلام, 2-ننطلق من الإستعلام(هي أفضل، وطرق حسابها ((manual, crowd, granfield paradigm))	12-ص62
تعريف نظامي (Aq)?prediction(Aq), ground truth(Rq):النتائج الصحيحة للنظام	13-ص63
تعريف نظامي ل precision & recall وذكر قانون كل منها؟بعض الملاحظات عن كيفية تحسينهما وتأثيرهما بعض	13-ص64
مشاكل ال precision&recall؟ففرضنا أننا نعلم relevance binary Rq, لا يوجد ترتيب	13-ص65
تعريف ال f(q) وذكر قانونه؟آخر لدمج قانوني ال precision&recall مع بعضهما	13-ص66
مثال على تطبيق p&r و (f(q))؟مسألة مليون وال 120 وثيقة	13-ص67
حل مشكلة ال ranking في p&r؟باستخدام Ranked p&r, مناقشة تأثير فقرات k على النظام الجيد ال P(تغير بيطرى) وال R(يجب أن يزداد سرعة عند كل قفزة)	13-ص68
مثال عن تطبيق ranked p&r؟مثال العشر وثائق، وضع النتيجة نفسها على شكل غراف وذكر طريقة رسمها	14-ص69
مثال بياني عن عدة أنظمة أخذنا ال Ranked p&r، وناقشنا من أفضل نظام منها بناء على الرسم البياني	15-ص70
تعريف ال Average precision(AP)؟عندما يكون لدينا قيمة ال P لكل عتبات ال k أحسن ما نرسمه بيانياً نأخذ وسيط القيم فنسميه AP، وإذا كان لدينا أكثر من استعلام حسب AP لكل منها ثم نأخذ الوسطي لها نسميه (MAP)	15-ص71
بعد أن حلنا مشكلة ال ranked ما هي الأشياء التي لم نحلها في ال p&r	15-ص72
تعريف ال user oriented precision؟معيار تقييم يأخذ معرفة المستخدم(k) بعين الاعتبار، يوجد رسمة توضيحية	15-ص73

تعريف عامل التغطية(coverage)، والnovelty في طريقة ال user oriented precision	74-ص16
تعريف ال gain,cumulative gain, discounted cumulative gain، هنا لكل وثيقة relevant خاص بها(ليس 1 و 0 فقط)، وأيضاً نأخذ تموض الوثيقة بعين الاعتبار (نقسم على لوغاریتم تموض الوثيقة لكي يكون قاسي على أول النتائج)	75-ص16
مثال عملي عن ال DCG؟ يوجد القانون، ومثال عن تطبيقه، ملاحظات عن هذه الطريقة ومذكور ال normalize DCG ما المقصود بال A/B testing؟	76-ص16
ذكر طريقة تقييم واجهات النظام؟ طريقة Ergonomic	77-ص17
تلخيص موجز لل vector (تعريفه، نتائجه) (الوثيقة تمثل بشعاع، الابعاد مستقلة، cos لحساب التشابه)، مشاكله (نضع index term بشكل يدوي، حساس للضجيج، لأنأخذ السياق بعين الاعتبار))	78-ص17
ما المقصود بتفكيك المصفوفة؟ وكيف نستخدمه بال R؟ صورة توضيحية للجزيء وذكر معنى كل سطر وعمود فيها	79-ص17
طريقة similar value decomposition (svd) لتجزيء المصفوفة ومناقشة خيارات التجزيء (low rank, spars)	80-ص17
تعريف LSI؟ وذكر فائدتها؟ حللت مشاكل homonyms, synonymous, compound words	81-ص18
نتائج تطبيق LSI؟ تمثيل الوثائق وبعد جديد، الوثائق المتشابهة قريبة من بعضها، تم حل الضجيج	82-ص18
مثال (السفن والخشب) عن تطبيق LSI؟ مع صورة توضيح التجزيء وذكر معنى المصفوفات المجزأة	83-ص18
نتائج تطبيق LSI؟ ضاء جديد كثيف (لا تحوي اصفار كثيرة)، لأنخذ السياق بعين الاعتبار، نتحكم بعدد الابعاد اذا لدينا وثيقة أو استعلام جديد كيف نضيفه للفضاء	84-ص18
إيجابيات وسلبيات خوارزمية LSI	85-ص19
كيف نعمل evaluation لLSI؟ نستخدم benchmark ونرى النتائج قبل وبعد تنفيذ ال LSI	86-ص19
ما المقصود ب index clustering؟ تجميع الوثائق المتشابهة ب cluster واحد	87-ص20
كيف نتعامل مع الإستعلام عندما يكون لدينا index clustering؟ نبحث عن أقرب مركز عنقود للإستعلام ونبحث فيه نوعي وضع الوثائق داخل ال soft, hard clustering	88-ص20
كيف نحكم على وثيقة أنها ب cluster معين؟ حسب المركز الأقرب على مركز العنقود بغض النظر عن كيفية تمثيل الفضاء (tf-idf, weight, BOW)	89-ص20
كيف نعمل evaluation لطريقة clustering؟ نستخدم benchmark ونرى النتائج قبل وبعد تنفيذ ال clustering	90-ص20
نوعي خوارزميات بناء ال Hierarchical(nearest-neighbor), Flat(k-means) clustering	91-ص20
مافائدة ال clustering؟ أصبحنا نضيف semantic information لكل عنقود، تمثيل الوثيقة على مستوى العنقود	92-ص20
كيف ممكن تطبيق clustering بالإستفادة من LSI؟ لأنخذ المصفوفة 7 ونرى كل وثيقة إلى أي cluster يجب أن تتنمي	93-ص21
ما المقصود ب PLSI؟ تطوير LDI؟ تطوير L PLSI؟ نأخذ topic وتحوي أيضاً احتمالات	94-ص21
ما المقصود ب semantic hashing؟ طريقة حديثة للنمذجة تعتمد على machine learning نحن نحدد الأبعاد ونطلب من الشبكة العصبية أن تمثل الوثائق فيها	95-ص21
Recap للمحاضرة؟ مافي شيء مهم	96-ص21
ملخص vector, boolean؟ موجود كل خصائص الجديدة: إنو مافي طريقة لمعرفة صحة النتائج لهياك متوجه للاحتمال	97-ص22
توضيح كيف نستخدم الإحتمالات للتأكد من صحة النتائج؟ يجب أن نعرف $P(R=1 d, q)$	98-ص22
توضيح طريقة حساب الإحتمالات ومعرفة القيم الواجب حسابها من أجل نمذجة الوثائق، يوجد صورة توضح القانون الأساسي Cx، وبشكل نظري للنمذجة بالإحتمالات: يجب أن نحسب احتمالين: $p(d r=0, q)$ و $p(d r=1, q)$	99-ص22
كيف يجب أن نحسب الإحتمالين: $p(d r=0, q)$ و $p(d r=1, q)$ ؟ عن طريق ال BIM نأخذ كل كلمة داخل الوثيقة على حد (موجود القانون) ويوجد قانون ال Cx العام لنمذجة الوثائق	100-ص23
إيجابيات وسلبيات ال BIM؟ نموذج أساسه الرياضي قوي، نموذج واضح وبسيط، له العديد من الباراميترات نتحكم بها، السليبيات: cold start، BOW: كل كلمة نتعامل معها لوحدها، لا ترابط بين الوثائق	101-ص24
مثال عملي لتطبيق قانون ال Px, Cx, Ux	102-ص24
تعريف نموذج BM25؟ جاء لحل مشاكل BIM، tf-idf، BOW: الحل، مشكلة الوثائق الطويلة: اللعب ب Cx، الكلمات المهمة وغيرها: اللعب بال Cx	103-ص25
إيجابيات وسلبيات ال BM25؟ نفس إيجابيات BIM، لا يوجد BOW، أفضل نموذج موجود، سليبيات: يأخذ فقط كلمات الإستعلام، لا يوجد علاقة بين ال term، نعتبر الوثائق مستقلة عن بعضها	104-ص25
ما هو Bayesian networks؟ فكرتها تأخذ الترابط بين الأحداث بعين الاعتبار	105-ص26
كيف نستفيد من Bayesian في ال IR؟ نقسم النظام لثلاث طبقات (الوثائق-الterms-words-كلمات الإستعلام)	106-ص26
إيجابيات وسلبيات Bayesian؟ تعميم ل BM25، تأخذ ترابط الوثائق وال terms بعين الاعتبار، سليبيات: ضعف التحقيق، كلفة عالية، غير موجود بعد	107-ص27
ما المقصود ب Logic model؟ نحوال الوثائق إلى جمل صحيحة في فضاء الوثيقة ($A \Rightarrow B$ entailment)	108-ص27
افتراضات Logic model؟ الوثيقة سلسلة جمل، كل إستعلام جملة، له ميزات النموذج الإحتمالي وأضاف عليها المعرفة	109-ص27

