

Consider the following sentences as the base text corpus:

- (1) المعلم يكتب درسا
- (2) يأكل الولد تفاحة
- (3) ذهب الولد إلى المدرسة
- (4) رجع الأب من السفر
- (5) في المدرسة كتب كثيرة متنوعة

Exercise N°1 (09 pts): We want to perform a HMM-based POS tagging. Use the base text corpus as training data:

- 1) Calculate the emission and the transition matrices (Provide a detailed description of the calculation process)
- 2) Draw the appropriate HMM diagram
- 3) Calculate the probability of generating the sentence: كتب الولد كثيرة متنوعة
- 4) Deduce the appropriate POS tags of each word of the sentence

Notes:

- a. Only consider the three POS tags (حرف ، إسم ، فعل) to tag the words of the text corpus
- b. For the verbs, use their lemma instead of their inflected forms throughout the process.
- c. Perform all calculations (matrices, diagrams) using a right-to-left reasoning

Solution:

1) Emission and Transition matrices

a. Assign each word in each sentence by the righth POS tag (1.25 pt)

المعلم	إسم	يكتب	فعل	درسا	إسم
يأكل	فعل	الولد	إسم	تفاحة	إسم
ذهب	فعل	الولد	إسم	إلى	حرف
رجع	فعل	الأب	إسم	من	حرف
كتب	فعل	المدرسة	إسم	كثيرة	إسم
				متنوعة	إسم

- b. Count the number of appearances of each word by tag , then divide each tag by the total number of their appearances (02 pts):

متنوعة	كثيرة	في	السفر	من	الأب	رجع	المدرسة	إلى	ذهب	تفاحة	الولد	أكل	درسا	كتب	المعلم	
0	0	0	0	0	0	1/4	0	0	1/4	0	0	1/4	0	1/4	0	فعل
1/12	1/12	0	1/12	0	1/12	0	2/12	0	0	1/12	2/12	0	1/12	1/12	1/12	إسم
0	0	1/3	0	1/3	0	0	0	1/3	0	0	0	0	0	0	0	حرف

- c. Emission matrix (0.5 pt):

متنوعة	كثيرة	في	السفر	من	الأب	رجع	المدرسة	إلى	ذهب	تفاحة	الولد	أكل	درسا	كتب	المعلم	
0	0	0	0	0	0	0.25	0	0	0.25	0	0	0.25	0	0.25	0	فعل
0.083	0.083	0	0.083	0	0.083	0	0.16	0	0	0.083	0.16	0	0.083	0.083	0.083	إسم
0	0	0.33	0	0.33	0	0	0	0.33	0	0	0	0	0	0	0	حرف

- d. Add the special tags (S) and (E) to each sentence (0.5 pt)

(E)	إسم	فعل	إسم	(S)
	درسا	يكتب	المعلم	
(E)	إسم	إسم	فعل	(S)
	تفاحة	الولد	يأكل	
(E)	إسم	حرف	إسم	(S)
	المدرسة	إلى	الولد	ذهب
(E)	إسم	حرف	إسم	(S)
	السفر	من	الأب	رجع
(E)	إسم	إسم	إسم	(S)
	متنوعة	كثيرة	كتب	المدرسة
			في	

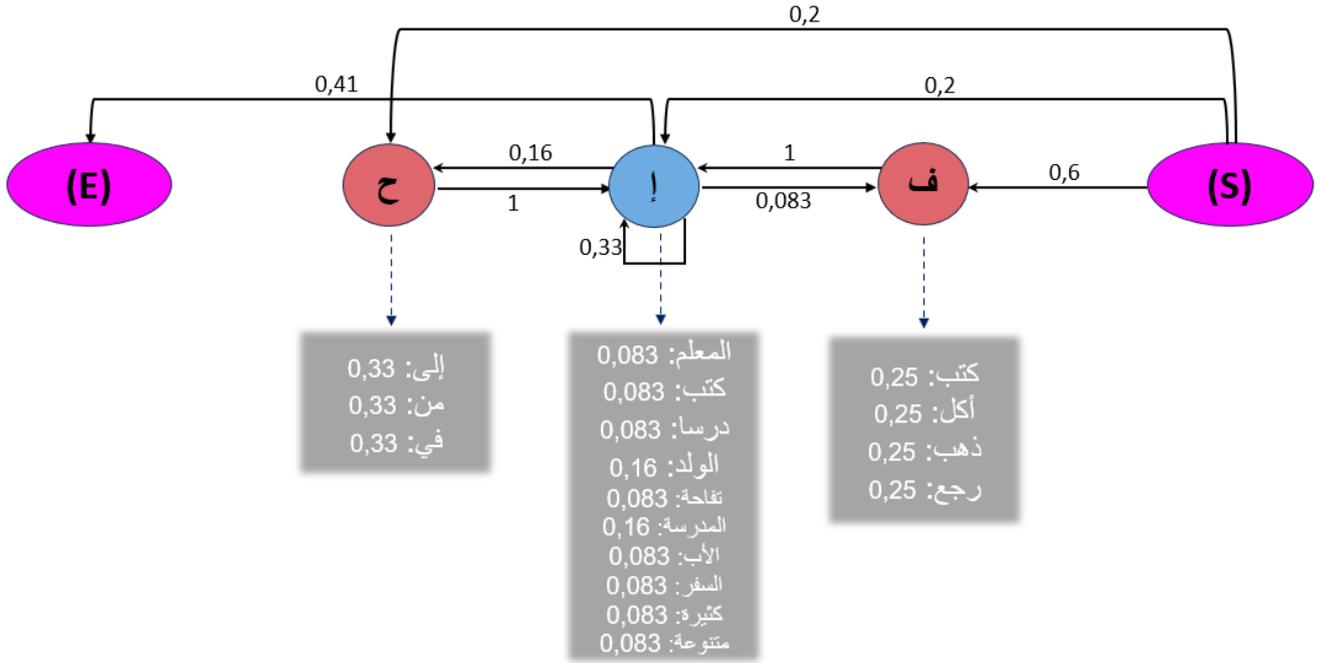
- e. Count the co-occurrences of each tag (number of times each tag is followed by another), then divide each term in a row by the total number of co-occurrences of the tag (01 pt)

(E)	حرف	إسم	فعل	
0	1/5	1/5	3/5	(S)
0	0	4/4	0	فعل
5/12	2/12	4/12	1/12	إسم
0	0	3/3	0	حرف

- f. Transition matrix (0.5 pt)

(E)	حرف	إسم	فعل	
0	0.2	0.2	0.6	(S)
0	0	1	0	فعل
0.41	0.16	0.33	0.083	إسم
0	0	1	0	حرف

2) HMM diagram (1.5 pt)



3) Calculate the probability of generating the sentence: كتب الولد كثيرة متنوعة (1.25 pt)

Path 1: (E) - (S) - فعل - (S) ←

Path 2 : (E) - (S) - (S) - (S) - (S) ←

$$P(\text{Path 1}) = 0.6 \times 0.25 \times 1 \times 0.16 \times 0.33 \times 0.083 \times 0.33 \times 0.083 \times 0.41 = 0.00000738 = 7.38 \times 10^{-6}$$

$$P(\text{Path 2}) = 0.2 \times 0.083 \times 0.33 \times 0.16 \times 0.33 \times 0.083 \times 0.33 \times 0.083 \times 0.41 = 0.000000269 = 0.26 \times 10^{-6}$$

$$P(\text{Sentence}) = P(\text{Path 1}) + P(\text{Path 2}) = 7.38 \times 10^{-6} + 0.26 \times 10^{-6} = 7.64 \times 10^{-6}$$

4) Deduce the appropriate POS tags of each word of the previous sentence (0.5 pt)

Path 1 is the **most probable** path, we say then that the appropriate POS tagging (according to our HMM) will be as follows:

إسم	إسم	إسم	فعل
متنوعة	كثيرة	الولد	كتب

Exercise N°2 (04 pts): We want to perform a **3-gram language model** with a **smoothing rate** of **0.2**.

Additionally to the base text corpus we include the two following sentences as training data:

(6) يأكل الولد خبزاً

(7) ذهب الولد غاضباً

1) Calculate the probability of generating "خبزاً" given the context "يأكل الولد"

2) Calculate the probability of generating "غاضباً" given the context "ذهب الولد"

Provide a detailed description of the calculation process

Solution:

1) Divide the training text corpus into 3-gram pieces:

- (1) المعلم يكتب درسا
- (2) يأكل الولد تفاحة
- (3) ذهب الولد إلى المدرسة
- (4) رجع الأب من السفر
- (5) في المدرسة كتب كثيرة متنوعة
- (6) يأكل الولد خبزا
- (7) ذهب الولد غاضبا

المعلم يكتب درسا	يكتب درسا يأكل	درسا يأكل الولد	يأكل الولد تفاحة	الولد تفاحة ذهب
تفاحة ذهب الولد	ذهب الولد إلى	الولد إلى المدرسة	إلى المدرسة رجع	المدرسة رجع الأب
رجع الأب من	الأب من السفر	من السفر في	السفر في المدرسة	في المدرسة كتب
المدرسة كتب كثيرة	كتب كثيرة متنوعة	كثيرة متنوعة يأكل	متنوعة يأكل الولد	يأكل الولد خبزا
الولد خبزا ذهب	خبزا ذهب الولد	ذهب الولد غاضبا		

- The text corpus consists of **23** 3-grams (1.5 pt)
- $|V| = 19$ unique words (Vocabulary size) (01 pt)

المعلم	يكتب	درسا	يأكل	الولد	تفاحة
ذهب	إلى	المدرسة	رجع	الأب	من
السفر	في	كتب	كثيرة	متنوعة	خبزا
19 unique words					غاضبا

- $\delta = 0.2$ (Smoothing rate)

$$P(w_i | w_{i-(n-1)}, \dots, w_{i-1}) = \frac{\delta + \text{Count}(w_{i-(n-1)}, \dots, w_{i-1}, w_i)}{\delta(|V|+1) + \text{Count}(w_{i-(n-1)}, \dots, w_{i-1})} \quad (0.5 \text{ pt})$$

2) Calculate the probability of generating "خبزا" given the context "يأكل الولد"

$$P("خبزا" | "يأكل الولد") = \frac{0.2 + \text{Count}("يأكل الولد خبزا")}{0.2 \times (19+1) + \text{Count}("يأكل الولد")} = \frac{0.2+1}{0.2 \times 20 + 2} = \frac{1.2}{6} = 0.2 \quad (0.5 \text{ pt})$$

3) Calculate the probability of generating "فرحا" given the context "ذهب الولد"

$$P("فرحا" | "ذهب الولد") = \frac{0.2 + \text{Count}("ذهب الولد فرحا")}{0.2 \times (19+1) + \text{Count}("ذهب الولد")} = \frac{0.2+0}{0.2 \times 20 + 2} = \frac{0.2}{6} = 0.033 \quad (0.5 \text{ pt})$$

Exercise N°3 (07 pts): Focus on sentence (5) in the base text corpus

- 1) Assign the correct Arabic POS tags to each word in the sentence
- 2) Define the Arabic syntactic role of each word in the sentence
- 3) Generate the appropriate Arabic syntax tree for the sentence
- 4) Construct the Arabic dependency graph for the sentence

- 5) We want to perform a TF-IDF encoding. Use the stemmed version of the base text corpus (including sentence 6 and 7, without stopwords) to calculate the importance of each word in sentence (5)

Solution:

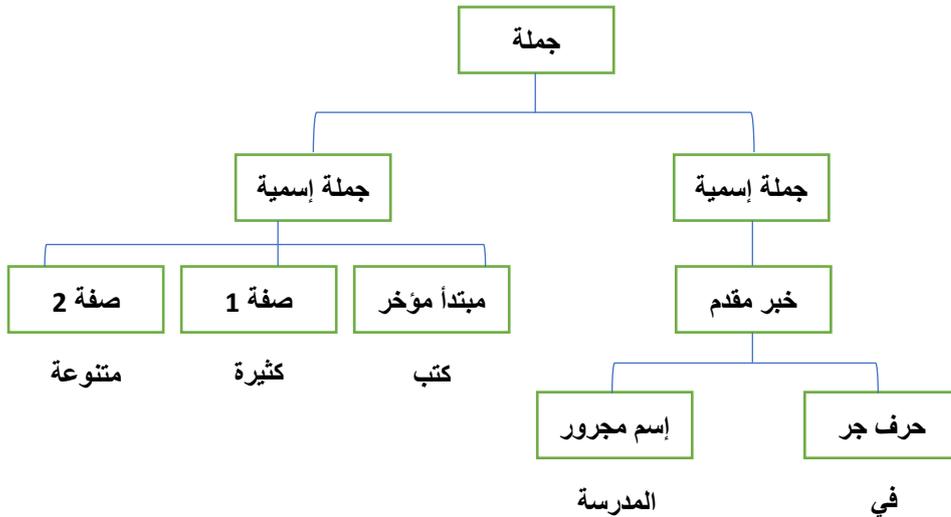
- 1) Assign the correct Arabic POS tags to each word in the sentence (01 pt)

صفة	صفة	إسم	إسم مجرور	حرف جر
متنوعة	كثيرة	كتب	المدرسة	في
Adjective	Adjective	Noun	Noun	Preposition

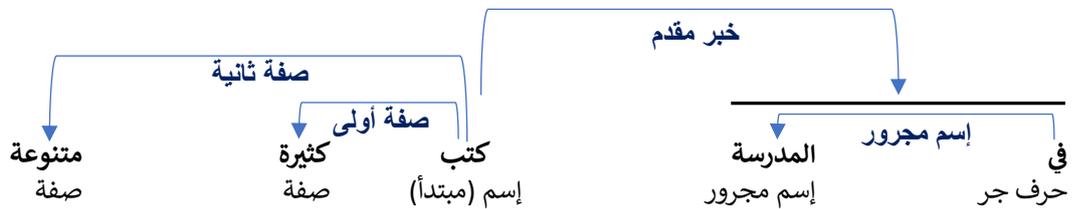
- 2) Define the Arabic syntactic role of each word in the sentence (01 pt)

صفة ثانية	صفة أولى	مبتدأ مؤخر	خبر مقدم	
صفة	صفة	إسم	إسم مجرور	حرف جر
متنوعة	كثيرة	كتب	المدرسة	في
Adjective	Adjective	Noun	Noun	Preposition

- 3) Generate the appropriate Arabic syntax tree for the sentence (1.25 pt)



- 4) Construct the Arabic dependency graph for the sentence (1.25 pt)



- 5) We want to perform a TF-IDF encoding. Use the stemmed version of the base text corpus (including sentence 6 and 7, without stopwords) to calculate the importance of each word in sentence (5) : (2.5 pts)

a. Preprocessing: (Stopword removal, Stemming) (0.5 pt)

Word	المعلم	يكتب	درسا	يأكل	الولد	تفاحة	ذهب	المدرسة	رجع	الأب	السفر	كتب	كثيرة	متنوعة	خبزا	غاضبا
Stem	علم	كتب	درس	أكل	ولد	تفح	ذهب	درس	رجع	أب	سفر	كتب	كثّر	نوع	خبز	غضب

b. TF-IDF (Sentence 5):

$$TF(\text{Term Frequency}) = \frac{\text{Number of occurrences of the word (stem) in sentence 5}}{\text{Number of words in sentence 5}} \quad (0.25 \text{ pt})$$

$$IDF(\text{Inverse Document Frequency}) = \log\left(\frac{\text{Number of sentences in the corpus}}{\text{Number of sentences that include the word (stem)}}\right) \quad (0.25 \text{ pt})$$

TF	متنوعة	كثيرة	كتب	المدرسة	في
(0.5 pt)	1/4=0.25	1/4=0.25	1/4=0.25	1/4=0.25	0

×

IDF	متنوعة	كثيرة	كتب	المدرسة	في
(0.5 pt)	$\log(7/1)=0.84$	$\log(7/1)=0.84$	$\log(7/2)=0.54$	$\log(7/2)=0.54$	0

=

TF×IDF	متنوعة	كثيرة	كتب	المدرسة	في
(0.5 pt)	0.21	0.21	0.13	0.13	0