

## Probabilités et statistiques pour le TAL

### Contrôle des connaissances - Correction

**Recommandations générales :** utilisez au maximum les notations vues en cours. Pour les résultats, inutile de développer/simplifier les factoriels. Pour les probabilités, définissez soigneusement l'ens. fondamental sur lequel travailler.

### 1 Cours

1.1. Donner les avantages et les inconvénients pour un linguiste de travailler par introspection versus travailler sur corpus.

	Avantages	Inconvénients
<b>introspection</b>	<ul style="list-style-type: none"> <li>- accès à des données inacceptables</li> <li>- accès immédiat aux constructions que l'on étudie</li> </ul>	<ul style="list-style-type: none"> <li>- données pas nécessairement attestées</li> <li>- difficile de quantifier les degrés d'acceptabilité</li> <li>- ne permet pas d'intégrer des informations quantitatives</li> </ul>
<b>corpus</b>	<ul style="list-style-type: none"> <li>- données attestées, éventuellement auxquelles on n'aurait pas pensé par introspection</li> <li>- permettent de quantifier les degrés d'acceptabilité de constructions</li> <li>- fournissent des informations quantitatives, qui sont maintenant considérées comme faisant partie de la compétence (au sens large) d'un locuteur : par ex. un mot rare a un « effet » différent d'un mot fréquent</li> </ul>	<ul style="list-style-type: none"> <li>- parcellaires</li> <li>- pas d'accès aux données agrammaticales, et donc argument de la « pauvreté du stimulus » : corpus sensés être insuffisants à eux seuls pour capturer la compétence</li> <li>- la probabilité de rencontrer un énoncé ne peut pas refléter l'acceptabilité : les énoncés acceptables rares vont être très difficiles à étudier en corpus</li> </ul>

1.2. Définissez ce qu'est un arrangement de r objets parmi n. Donnez le nombre d'arrangements de r objets parmi n, en justifiant ce résultat.

⇒ On a n possibilités pour le premier élément, (n-1) pour le second, (n-2) pour le troisième etc... On obtient par le principe fondamental de dénombrement :  $n(n-1)(n-2)...(n-r+1)$ , qui peut s'écrire  $n!/(n-r)!$

1.3. Définissez ce qu'est une combinaison de r objets parmi n. Donnez le nombre de combinaisons de r objets parmi n. Justifiez ce résultat en partant du nombre d'arrangements.

⇒ Une combinaison est un ensemble de r objets pris parmi n. C'est l'équivalent non ordonné des arrangements. Si on considère les  $n!/(n-r)!$  arrangements de r objets parmi n, on peut faire des « paquets » d'arrangements, qui sont identiques modulo l'ordre des éléments. Chaque paquet correspond donc exactement à une combinaison. En outre, chacun de ces paquets contient r! éléments, i.e. les r! façons d'arranger les r éléments. On obtient ainsi le nb de combinaisons en divisant  $n!/(n-r)!$  par r!

*On peut écrire tout est comme l'union d'un certain nb d'événements élémentaires.*

1.4. Donnez la définition axiomatique des probabilités.

⇒ voir cours

1.5. Dans le cas d'un ensemble fondamental S à événements élémentaires équiprobables, si E est un événement quelconque sur S, combien vaut P(E) ?

⇒ En notant N(E) le nombre d'éléments de l'événement E, on aura  $P(E) = N(E) / N(S)$

*Événement → tout sous-ensemble de l'ensemble fondamental.  
Et élémentaire → 1 seule issue*

### 2 Exercices

2.1. Un enfant a appris 10 mots d'italien : 2 déterminants, 4 noms et 4 verbes.

a) Combien peut-il former de phrases de la forme Det N V Det N (dans le cas où chaque mot peut être utilisé plus d'une fois) ?

⇒ On peut décomposer l'expérience « former une phrase de la forme Det N V Det N » en une suite de plusieurs : « choisir un Det parmi 2 », « choisir un N parmi 4 » etc... Comme on peut réutiliser chaque mot, on a toujours 2 det, 4 noms et 4 verbes possibles. D'où d'après le principe fondamental de dénombrement :

$$\text{nombre de telles phrases} = 2 \times 4 \times 4 \times 2 \times 4 = 256$$

b) Combien de séquences de mots sont formables (en utilisant chaque mot une fois, et sans considérer les contraintes syntaxiques sur les séquences) ?

⇒ Il s'agit du nombre de permutations des 10 mots = 10!

c) Combien de séquences de catégories sont formables (en utilisant chaque mot une fois, et sans considérer les contraintes syntaxiques sur les séquences) ?

⇒ Il s'agit du nombre de permutations des 10 mots, dont respectivement 2, 4, et 4 forment des paquets indiscernables. D'où la réponse :  $10! / 2!4!4!$

2.2. Un professeur organise un concours de poésie dans sa classe de 12 élèves. Combien de façons a-t-il de choisir 3 équipes de 4 élèves ?

⇒ Commençons par considérer le cas où l'ordre des équipes est pertinent : on a alors  $C_{12}^4$  façons de choisir les membres de la 1ère équipe, puis  $C_8^4$  façons de choisir la seconde, ce qui dans le même temps choisit la troisième. Donc on aura  $C_{12}^4 C_8^4$  façons d'obtenir des triplets ordonnés d'équipes.

Mais dans la question posée, peu importe l'ordre des équipes, dans le résultat précédent on a des triplets d'équipes, qui forment des paquets de 3! triplets équivalents pour peu que l'ordre ne soit plus considéré. D'où le résultat :  $C_{12}^4 C_8^4 / 3!$

2.3. Le même enfant n'a toujours que 10 mots d'italien. Il énumère au hasard les 10 mots qu'il connaît.

a) Quelle est la probabilité d'une séquence donnée ?

⇒ L'ens. fondamental est le nb de permutations des 10 mots, il y en a 10!

L'énumération se faisant au hasard, chaque événement élémentaire (i.e. ici chaque permutation) est équiprobable. La proba d'une des permutations est donc  $1 / 10!$

b) Quelle est la probabilité que le deuxième mot soit un verbe ?

⇒ On a 4 façons de choisir le verbe apparaissant en deuxième mot, et 9! façons d'ordonner les autres mots. D'où le résultat =  $4 \times 9! / 10! = 4/10$

- 2.4. On tire 5 cartes au hasard parmi un jeu de 52. Quelle est la probabilité de l'événement  $E =$  « avoir au moins une carte rouge et au moins une carte noire » ? **Indications :** utilisez les événements  $N =$  « il n'y a que des noires » et  $R =$  « il n'y a que des rouges ».

a) donnez  $P(N)$  et  $P(R)$

$\Rightarrow$  L'ens. fondamental est composé des  $C_{52}^5$  combinaisons de 5 cartes parmi 52. L'événement  $N$  comporte  $C_{26}^5$  éléments, i.e. le nombre de façons de choisir 5 cartes parmi les 26 noires. Idem pour  $R$ .

$$\text{D'où } P(N) = P(R) = \frac{C_{26}^5}{C_{52}^5} = \frac{26!}{5!21!} \frac{5!47!}{52!} = \frac{23 \times 11}{2 \times 2 \times 51 \times 49} = 0,0253\dots$$

b) Quel axiome des probabilités utiliser pour calculer  $P(N \cup R)$  ?

$\Rightarrow$  Les deux évènements sont mutuellement exclusifs, donc par l'axiome d'additivité :

$$P(N \cup R) = P(N) + P(R)$$

c) Exprimer  $E$  en fonction de  $N$  et  $R$  (et éventuellement complémentaires), utilisez une loi de Morgan, en déduire le résultat...

$\Rightarrow$  On a  $E =$  « avoir au moins une carte rouge »  $\cap$  « avoir au moins une carte noire »

Or « avoir au moins une carte rouge » est exactement « ne pas avoir que des noires », c'est à dire  $\bar{N}$

donc on a  $E = \bar{N} \cap \bar{R}$ , donc par une des lois de Morgan  $E = \bar{N} \cap \bar{R} = \overline{N \cup R}$ ,

$$\text{d'où } P(E) = P(\overline{N \cup R}) = 1 - P(N \cup R)$$

et d'après b) on obtient  $P(E) = 1 - P(N \cup R) = 1 - P(N) - P(R) = 0,95$ ,