

# Lois de probabilité

## Variables discrètes

Anita Burgun

Cours PCEM 1 (2006-2007)

# Problème posé

- Le problème posé en statistique:
  - On s'intéresse à une population
  - On extrait un échantillon
  - On se demande quelle sera la composition de l'échantillon (pourcentage théorique vs pourcentage observé)
  - Calcul des probabilités : lois

# Contenu des cours

- Loi binomiale
- Loi hypergéométrique
- Loi de Poisson
- Loi normale
- Loi du  $\chi^2$  (définition)
- Loi T de Student (définition)

# Contenu des cours

- Loi binomiale
- *Loi hypergéométrique*
- *Loi de Poisson*
- *Loi normale*
- *Loi du chi<sup>2</sup> (définition)*
- *Loi T de Student (définition)*

# Rappel

- Une v.a.  $X$  est discrète si l'ensemble des réalisations possibles  $x_1, x_2, \dots, x_n$  pour cette variable est fini ou dénombrable.
- Famille de 4 enfants dont les deux parents sont porteurs d'un gène d'une maladie héréditaire.  
Nombre d'enfants atteints.  $X=0,1,2,3,4$
- Nombre d'étudiants ayant les yeux bleus en PCEM1.  $X=0,1,2,\dots,n$

# Définition

- A chacune des réalisations  $x_i$  de la v.a.  $X$  est associée une probabilité  $P(X=x_i) = p_i$

$$\forall i, 0 \leq p_i \leq 1$$

- L'ensemble des couples  $(x_i, p_i)$  forme une loi de probabilité.

$$\sum_{i=0}^n p_i = 1$$

# Loi de Bernoulli

- Soit une expérience aléatoire ayant deux résultats possibles :
  - le succès (probabilité  $p$ )
  - ou l'échec ( $q=1-p$ )
- Famille de 4 enfants dont les deux parents sont porteurs d'un gène d'une maladie héréditaire (récessive).
- La v.a. « avoir la maladie  $m$  » suit une loi de Bernoulli de paramètre  $p$  égal à 0.25
- $E(X) = p$                        $V(X) = p(1-p)$

# Loi binomiale

- On répète  $n$  fois dans des conditions identiques une expérience aléatoire dont l'issue se traduit par l'apparition ou la non apparition d'un événement  $A$  de probabilité  $p$ , le résultat de chaque expérience étant indépendant des résultats précédents.
- Soit  $X$  le nombre d'apparitions de l'événement  $A$  parmi ces  $n$  expériences ( $0 \leq X \leq n$ ).
- $X$  suit une loi binomiale de paramètres  $n$  et  $p$ .

$$\mathcal{B}(n; p)$$

# Loi binomiale

- *On répète  $n$  fois dans des conditions identiques une expérience aléatoire dont l'issue se traduit par l'apparition ou la non apparition d'un événement  $A$  de probabilité  $p$ , le résultat de chaque expérience étant indépendant des résultats précédents.*
- *Soit  $X$  le nombre d'apparitions de l'événement  $A$  parmi ces  $n$  expériences ( $0 \leq X \leq n$ ).*
- *$X$  suit une loi binomiale de paramètres  $n$  et  $p$ .*
- **A chaque expérience on peut associer une variable de Bernoulli**

# Loi binomiale (def 2)

- La somme de  $n$  v.a. de Bernoulli  $Y_i$  indépendantes et de même paramètre  $p$  est une v.a. discrète qui suit une loi binomiale de paramètres  $n$  et  $p$

$$X = \sum_{i=1}^n Y_i$$

# Loi binomiale

$$p(X = k) = \mathbf{C}_n^k p^k (1 - p)^{n-k}$$

Proba d'obtenir  
k succès

Nombre de manières  
de choisir k  $X_i$  parmi n

Proba d'obtenir  
(n-k) échecs

The diagram illustrates the components of the binomial probability formula. The formula is  $p(X = k) = \mathbf{C}_n^k p^k (1 - p)^{n-k}$ . Three arrows point from descriptive text to parts of the formula: one from 'Nombre de manières de choisir k  $X_i$  parmi n' to the binomial coefficient  $\mathbf{C}_n^k$ ; one from 'Proba d'obtenir k succès' to the term  $p^k$ ; and one from 'Proba d'obtenir (n-k) échecs' to the term  $(1 - p)^{n-k}$ .

# Loi binomiale

$$p(X = k) = \mathbf{C}_n^k p^k (1-p)^{n-k}$$

$$P_k = p(X = k) = \frac{n!}{k! (n-k)!} p^k (1-p)^{n-k}$$

# Loi BINOMIALE

$$p(X = k) = \mathbf{C}_n^k p^k (1-p)^{n-k}$$

Loi BINOMIALE parce que ses différents termes sont les termes du développement de  $(p+(1-p))^n$  selon la formule du binôme de Newton

$$(a + b)^n = \sum_{k=0}^n \mathbf{C}_n^k a^k b^{n-k}$$

$$(p + (1 - p))^n = \sum p_k = 1$$

$$P_0 = (1 - p)^n$$

$$P_{k+1} = \frac{n!}{(k+1)!(n-(k+1))!} p^{k+1} (1-p)^{n-k-1}$$

$$P_{k+1} = \frac{n-k}{k+1} \frac{n!}{k!(n-k)!} \frac{p}{(1-p)} p^k (1-p)^{n-k}$$

$$P_{k+1} = \frac{p}{(1-p)} \frac{n-k}{k+1} P_k$$

Pour aider dans les calculs

$$(k + 1)! = (k + 1) \times k!$$

$$k! = \frac{(k + 1)!}{k + 1}$$

$$\frac{1}{k!} = \frac{k + 1}{(k + 1)!}$$

# Espérance, variance

- La somme de  $n$  v.a. de Bernoulli  $Y_i$  indépendantes et de même paramètre  $p$  est une v.a. discrète qui suit une loi binomiale de paramètres  $n$  et  $p$

$$X = \sum_{i=1}^n Y_i$$

# Espérance

$$E(X_1 + X_2) = E(X_1) + E(X_2)$$

$$X \sim \mathcal{B}(n; p)$$

$$E(X) = \sum E(Y_i)$$

$$E(X) = np$$

# Variance

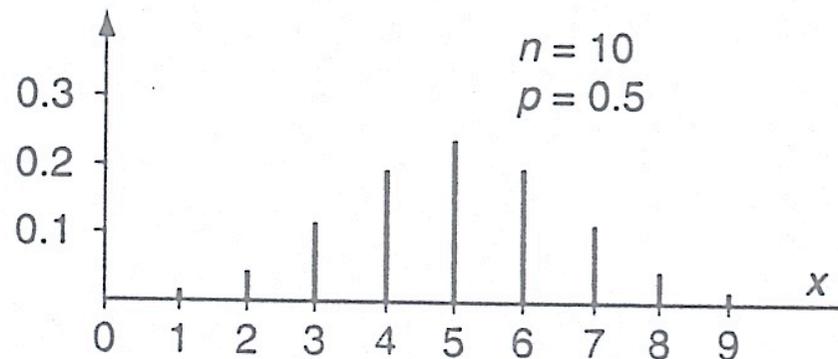
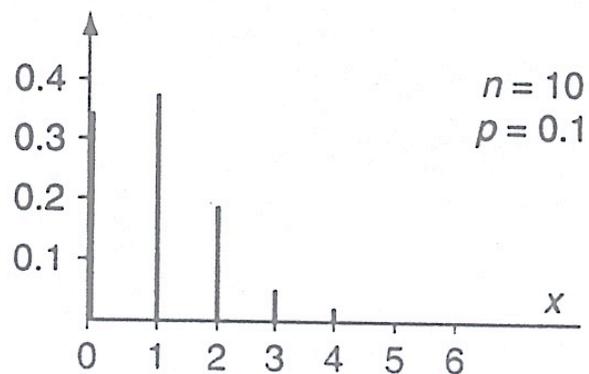
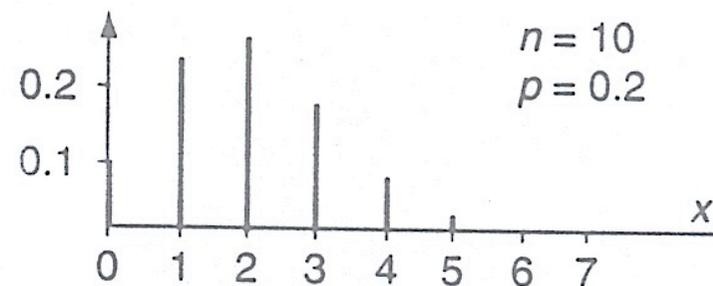
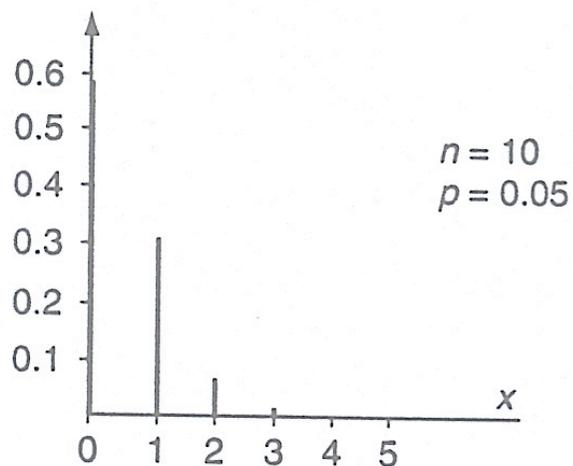
$$V(X_1 + X_2) = V(X_1) + V(X_2)$$

$$X \sim \mathcal{B}(n; p)$$

$$V(X) = \sum V(Y_i)$$

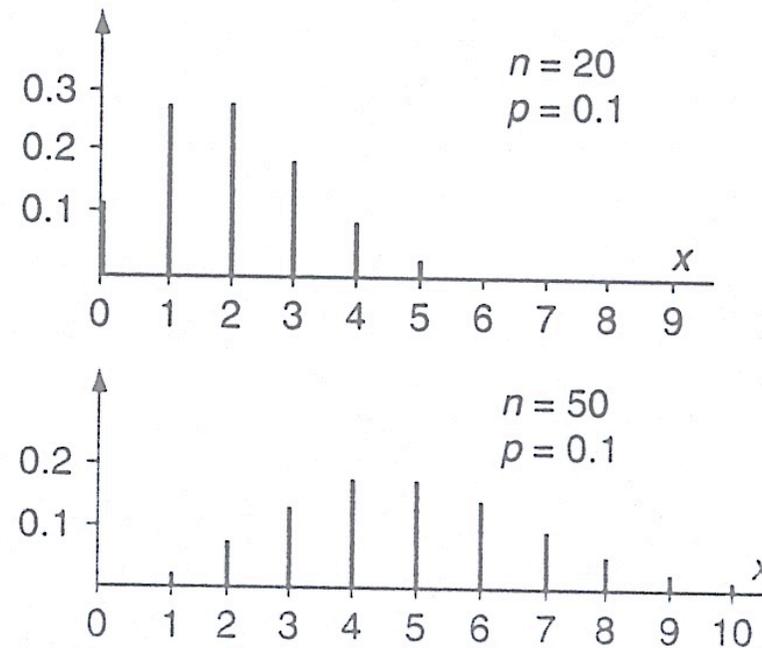
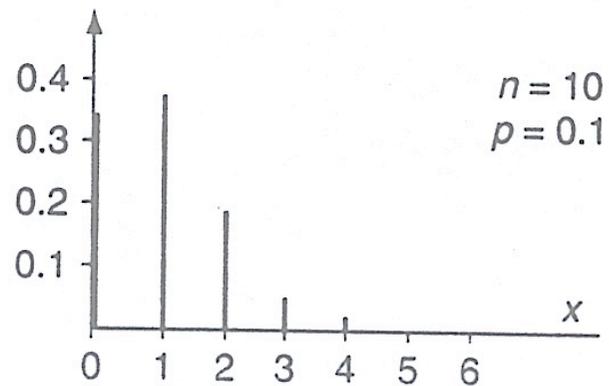
$$V(X) = n p (1-p)$$

# Représentation graphique (1)



Tiré de G Saporta, Probabilités, analyse de données et statistique Technip

# Représentation graphique (2)



Tiré de G Saporta, Probabilités, analyse de données et statistique Technip

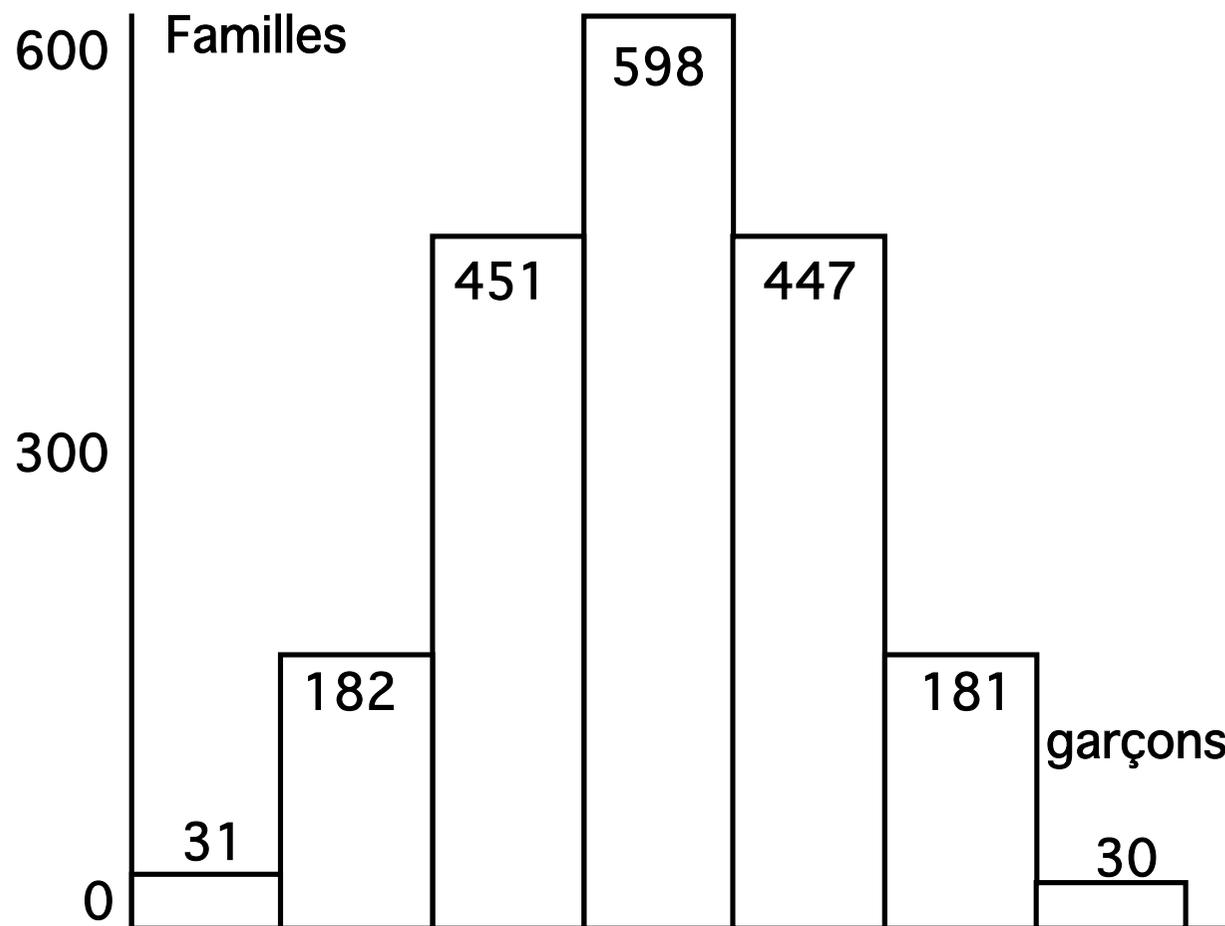
# Remarques utiles

- Dans certaines circonstances, la loi binomiale peut être approximée soit par une loi de Poisson ( $p$  petit) soit par une loi normale.
- La somme de 2 v.a. binomiales indépendantes et de même paramètre  $p$  est une v.a. binomiale

$$X_1 + X_2 \quad \mathcal{B}(n_1+n_2; p)$$

# Illustration

- Répartition des sexes à la naissance:  $p=1/2$
- Famille de 6 enfants      loi binomiale  $n=6$  et  $p=0.5$ 
  - $(1-p)^6 = 1/64 = 1,6\%$       pour 0 garçon
  - $6p(1-p)^5 = 6/64 = 9,4\%$       pour 1 garçon
  - $15p^2(1-p)^4 = 15/64 = 23,4\%$       pour 2 garçons
  - $20p^3(1-p)^3 = 20/64 = 31,2\%$       pour 3 garçons
  - $15p^4(1-p)^2 = 15/64 = 23,4\%$       pour 4 garçons
  - $6p^5(1-p) = 6/64 = 9,4\%$       pour 5 garçons
  - $p^6 = 1/64 = 1,6\%$       pour 6 garçons



D'après Lamotte (total: 1920 familles)

# Contenu des cours

- *Loi binomiale*
- *Loi de Poisson*
- Loi hypergéométrique
- *Loi normale*
- *Loi du chi<sup>2</sup>*
- *Loi de Student*

# Loi hypergéométrique

- La loi du tirage exhaustif
- Puce à ADN avec des gènes annotés fonctionnellement
- Annotations les plus représentatives

# Définition

- Soit une population de  $N$  individus parmi lesquels une proportion  $p$  (donc  $Np$  individus) possède un caractère. On prélève un échantillon de  $n$  individus parmi cette population (le tirage pouvant s'effectuer d'un seul coup ou au fur et à mesure mais sans remise). Soit  $X$  le nombre aléatoire d'individus de l'échantillon possédant la propriété considérée.
- $X$  suit une loi hypergéométrique

# Définition

- $X$  suit une loi hypergéométrique

Nb de groupes de  $x$  individus possédant la propriété

Nb de groupes de  $(n-x)$  individus ne possédant pas la propriété

$$P(X = x) = \frac{C_{Np}^x C_{N-Np}^{n-x}}{C_N^n}$$

Nb d'échantillons possibles

$$X \sim \mathcal{H}(N, n, p)$$

## Espérance, variance

$$E(X) = np$$

$$V(X) = \frac{N - n}{N - 1} np(1 - p)$$

# Illustration

- Un étudiant passant un oral de mathématiques choisit dans une urne 5 enveloppes contenant chacune une question à tirer. Il y a dans l'urne, au total, 12 questions de statistique et 8 questions d'algèbre. On appelle  $X$  le nombre de questions de statistique qu'il a tirées.  $E(X)$ ?  $V(X)$ ?

# Illustration

- Un étudiant passant un oral de mathématiques choisit dans une urne 5 enveloppes contenant chacune une question à tirer. Il y a dans l'urne, au total, 12 questions de statistique et 8 questions d'algèbre. On appelle  $X$  le nombre de questions de statistique qu'il a tirées.  $E(X)$ ?  
 $V(X)$ ?

$$E(X) = 5 \times 0.6 = 3$$

$$V(X) = np(1-p) \frac{N-n}{N-1} = 5 \times 0.6 \times 0.4 \times \frac{15}{19} = 0.9474$$

# Hypergéométrique $\rightarrow$ binomiale

quand  $N \rightarrow \infty$ ,

$\{X \sim \mathcal{H}(N, n, p)\}$  peut être approximée par

$\{X \sim \mathcal{B}(n, p)\}$

- En pratique quand  $n/N < 1/10$  (d'après Saporta, Schwartz)

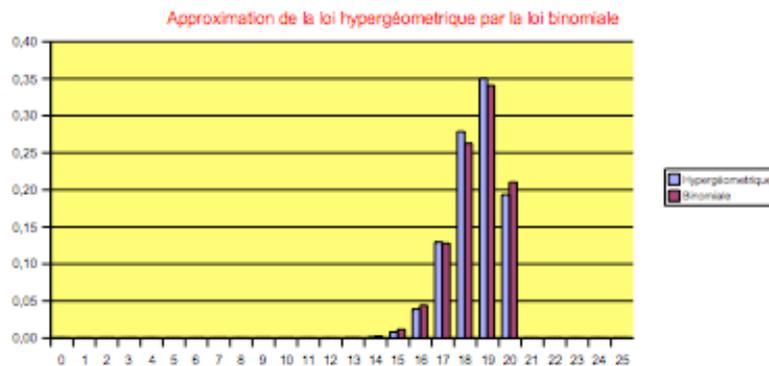
**Approximation binomiale de la loi hypergéométrique:**

N		n	Rapport des variances	
s		p	VH/VB	
185		0,93	0,9	
x	P(X=x) Hypergéométrique	P(X=x) Binomiale	H-B Différence	
0	0,00000E+000	3,17121E-023	-3,17121E-023	
1	0,00000E+000	7,82232E-021	-7,82232E-021	
2	0,00000E+000	9,16515E-019	-9,16515E-019	
3	0,00000E+000	6,78221E-017	-6,78221E-017	
4	0,00000E+000	3,55501E-015	-3,55501E-015	
5	1,05978E-018	1,40304E-013	-1,40303E-013	
6	4,76902E-016	4,32605E-012	-4,32558E-012	
7	8,53655E-014	1,06709E-010	-1,06624E-010	
8	8,23066E-012	2,13863E-009	-2,13040E-009	
9	4,85609E-010	3,51686E-008	-3,46830E-008	
10	1,88028E-008	4,77121E-007	-4,58318E-007	
11	4,98558E-007	5,34954E-006	-4,85098E-006	
12	9,29455E-006	4,94832E-005	-4,01887E-005	
13	1,23689E-004	3,75565E-004	-2,51876E-004	
14	1,18192E-003	2,31598E-003	-1,13407E-003	
15	8,08431E-003	1,14255E-002	-3,34121E-003	
16	3,90436E-002	4,40359E-002	-4,99231E-003	
17	1,29380E-001	1,27790E-001	1,58928E-003	
18	2,78664E-001	2,62680E-001	1,59837E-002	
19	3,49901E-001	3,41023E-001	8,87782E-003	
20	1,93612E-001	2,10298E-001	-1,66858E-002	
21	0,00000E+000	0,00000E+000	0,00000E+000	
22	0,00000E+000	0,00000E+000	0,00000E+000	
23	0,00000E+000	0,00000E+000	0,00000E+000	
24	0,00000E+000	0,00000E+000	0,00000E+000	
25	0,00000E+000	0,00000E+000	0,00000E+000	
Différence maximale en valeur absolue			1,66858E-002	

N= 200, n=20  
p= 0.93

Tiré de:

<http://www-timc.imag.fr/Cecile.Amblard/Enseignement/STA230/sortieTP3.pdf>



# Lois de probabilité (2/3)

Anita Burgun

# Contenu des cours

- *Loi binomiale*
- *Loi hypergéométrique*
- Loi de Poisson
- *Loi normale*
- *Loi du chi<sup>2</sup>*
- *Loi de Student*

# Loi de Poisson

- La loi des évènements rares
- Survenue d'un accident lors des examens radiologiques
- Effets secondaires des médicaments (pharmacovigilance)

# Notion de processus de Poisson

- Il faut que 3 hypothèses soient vérifiées
- Proba qu'un accident sur intervalle de temps  $dt$  proportionnel à durée  
 $\lambda$  = nb moyen d'accidents par unité de temps
- Proba d'observer 2 accidents au cours de  $dt$  est très faible par rapport à celle d'en observer 1
- Le nombre d'accidents survenant dans un intervalle de temps donné est indépendant du fait qu'on ait observé beaucoup, ou peu d'accidents dans un autre intervalle de temps précédent.

# Loi de Poisson

- Une v.a.  $X$  suit une loi de Poisson de paramètre réel positif  $\lambda$ , notée

$$X \sim \mathcal{P}(\lambda)$$

si elle suit:

$$P(X = k) = e^{-\lambda} \frac{\lambda^k}{k!}$$

# C'est une loi de probabilité

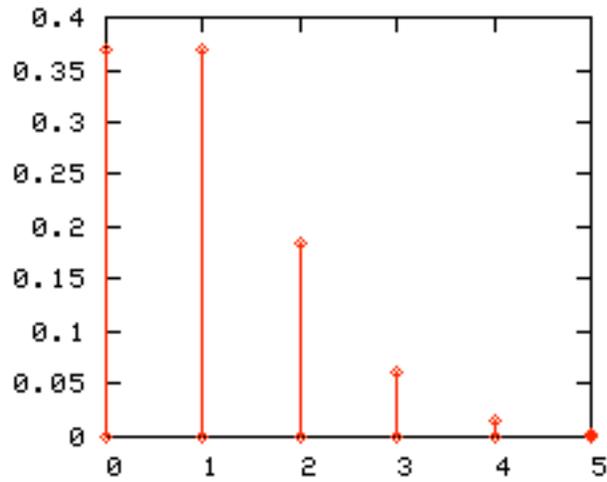
- Rappel 
$$e^u = 1 + u + \frac{u^2}{2!} + \frac{u^3}{3!} + \dots + \frac{u^n}{n!} + \dots = \sum_{k=0}^{+\infty} \frac{u^k}{k!}$$

- Loi de probabilité 
$$\sum_{k=0}^{+\infty} p_k = 1$$

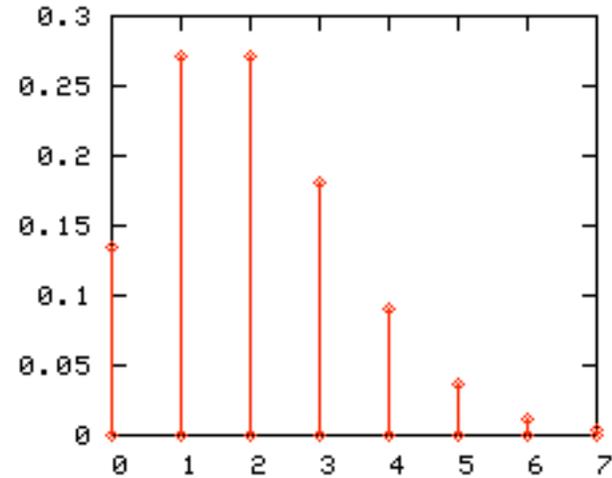
$$\sum_{k=0}^{+\infty} p_k = e^{-\lambda} \sum_{k=0}^{+\infty} \frac{\lambda^k}{k!} = e^{-\lambda} e^{\lambda} = 1$$

# Représentation graphique

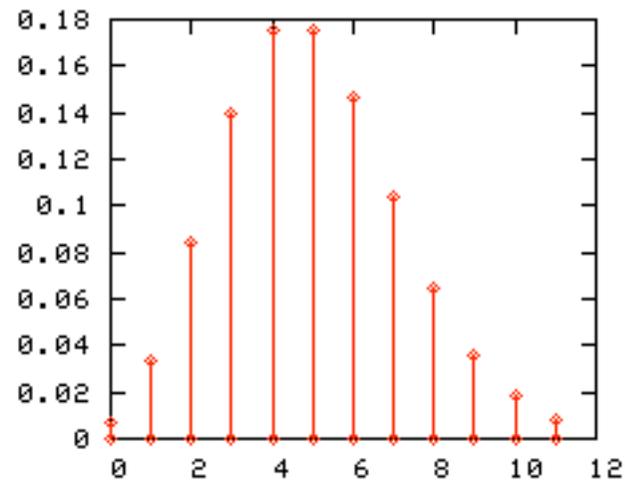
$\lambda=1$



$\lambda=2$



$\lambda=5$



# Espérance, variance

$$E(X) = \lambda$$

$$V(X) = \lambda$$

# Montrons que $E(X) = \lambda$

Rappel : 
$$e^\lambda = \sum_{k=0}^{+\infty} \frac{\lambda^k}{k!}$$

$$E(X) = \sum_{k=0}^{+\infty} k e^{-\lambda} \frac{\lambda^k}{k!} = e^{-\lambda} \sum_{k=0}^{+\infty} k \frac{\lambda^k}{k!} = e^{-\lambda} \sum_{k=1}^{+\infty} \frac{\lambda^k}{(k-1)!}$$

$$E(X) = e^{-\lambda} \sum_{k=1}^{+\infty} \lambda \frac{\lambda^{k-1}}{(k-1)!} = \lambda e^{-\lambda} \sum_{k=1}^{+\infty} \frac{\lambda^{k-1}}{(k-1)!}$$

Si on pose  $m = k-1$ , on a : 
$$\sum_{k=1}^{+\infty} \frac{\lambda^{k-1}}{(k-1)!} = \sum_{m=0}^{+\infty} \frac{\lambda^m}{m!} = e^\lambda$$

Donc : 
$$E(X) = \lambda e^{-\lambda} e^\lambda = \lambda$$

# Remarques utiles

- Lorsque la v.a.  $X$  suit une loi de Poisson

$$p_0 = P(X = 0) = e^{-\lambda} \quad (\text{probabilité qu'il n'y ait aucun accident})$$

$$p_{1+} = P(X > 0) = 1 - e^{-\lambda} \quad (\text{probabilité qu'il y ait au moins un accident})$$

## Remarques utiles (2)

- Si  $X_1 \sim \mathcal{P}(\lambda_1)$  et  $X_2 \sim \mathcal{P}(\lambda_2)$  avec  $X_1$  et  $X_2$  deux v.a. indépendantes alors  $X$ , somme de  $X_1$  et  $X_2$  suit une loi de Poisson

$$X \sim \mathcal{P}(\lambda_1 + \lambda_2)$$

- Un traitement produit 2 types d'accidents, les accidents cutanés et les accidents digestifs

# Binomiale $\rightarrow$ Poisson: illustration

- Un liquide contient  $10^5$  bactéries par litre. On en prélève  $1 \text{ mm}^3$ . Quelle est la probabilité que ce prélèvement ne contienne aucune bactérie?  
Contienne 1, 2, 3 bactéries?

# Binomiale -> Poisson: illustration

- *Un liquide contient  $10^5$  bactéries par litre. On en prélève  $1 \text{ mm}^3$ . Quelle est la probabilité que ce prélèvement ne contienne aucune bactérie? Contienne 1, 2, 3 bactéries?*
- La probabilité pour qu'une bactérie donnée soit dans le  $\text{mm}^3$  prélevé est, si les bactéries sont réparties au hasard dans le liquide, c'est à dire si elles ont autant de chances d'être dans chacun des  $10^6 \text{ mm}^3$  du litre,

$$\frac{1}{10^6}$$

# Binomiale -> Poisson: illustration

- *Un liquide contient  $10^5$  bactéries par litre. On en prélève  $1 \text{ mm}^3$ . Quelle est la probabilité que ce prélèvement ne contienne aucune bactérie? Contienne 1, 2, 3 bactéries?*
- *La probabilité pour qu'une bactérie donnée soit dans le  $\text{mm}^3$  prélevé est  $1/10^6$*
- Nous avons  $10^5$  bactéries au total
- Donc le nombre de bactéries contenues dans le prélèvement est régi par une loi binomiale de paramètres

$$p = 10^{-6}$$

$$n = 10^5$$

# Binomiale -> Poisson: illustration

- *La probabilité pour qu'une bactérie donnée soit dans le mm<sup>3</sup> prélevé est 1/10<sup>6</sup>. Nous avons 10<sup>5</sup> bactéries au total. Donc le nombre de bactéries contenues dans le prélèvement est régi par une loi binomiale de paramètres  $p = 10^{-6}$   $n = 10^5$*

$$P_0 = (1 - p)^n = (1 - 10^{-6})^{10^5} = 0.90$$

$$P_1 = 10^{-6} \frac{10^5}{1} P_0 = 0.09$$

$$P_2 = 10^{-6} \frac{10^5}{2} P_1 = \frac{P_1}{20} = 0.0045$$

$$P_3 = 10^{-6} \frac{10^5}{3} P_2 = \frac{P_2}{30} = 0.00015$$

Par récurrence,  
en confondant  $1 - 10^{-6}$   
avec 1 et en négligeant  
1 ou 2 devant  $10^5$

# Binomiale -> Poisson: illustration

- *La probabilité pour qu'une bactérie donnée soit dans le mm<sup>3</sup> prélevé est 1/10<sup>6</sup>. Nous avons 10<sup>5</sup> bactéries au total. Donc le nombre de bactéries contenues dans le prélèvement est régi par une loi binomiale de paramètres  $p = 10^{-6}$   $n = 10^5$*

$P_k$  décroît très vite quand  $k$  augmente

L'espérance du nb de bactéries contenues dans le prélèvement est  $np = 0.1$

La variance  $np(1-p)$  est pratiquement égale à  $np$  (donc  $E$ ).

# Approximation binomiale-> Poisson

- La loi binomiale  $\mathcal{B}(n; p)$  se confond quand  $n$  grand et  $p$  petit avec une loi de Poisson de paramètre  $\lambda = np$ .
- Elle modélise donc les expériences de Bernoulli avec une très faible probabilité de succès, mais avec un grand nombre d'essais ( $np$  quasiment constant).
- On considère  $p < 0.1$  et  $n > 50$   
(source: Lazar, Schwartz)

### Approximation poissonnienne de la loi binomiale:

N		200		Rapport des variances VH/VB	
P		0,015		3	
Lambda		0,015		0,99	
x	P(X=x) Poisson	P(X=x) Binomiale	P-B Différence		
0	4,97871E-002	4,86683E-002	1,11878E-003		
1	1,49361E-001	1,48228E-001	1,13291E-003		
2	2,24042E-001	2,24600E-001	-5,57924E-004		
3	2,24042E-001	2,25740E-001	-1,69802E-003		
4	1,68031E-001	1,69305E-001	-1,27352E-003		
5	1,00819E-001	1,01067E-001	-2,48462E-004		
6	5,04094E-002	5,00206E-002	3,88801E-004		
7	2,16040E-002	2,11109E-002	4,93087E-004		
8	8,10151E-003	7,75586E-003	3,45651E-004		
9	2,70050E-003	2,51967E-003	1,80833E-004		
10	8,10151E-004	7,32879E-004	7,72724E-005		
11	2,20950E-004	1,92774E-004	2,81765E-005		
12	5,52376E-005	4,62364E-005	9,00121E-006		
13	1,27471E-005	1,01825E-005	2,56466E-006		
14	2,73153E-006	2,07120E-006	6,60330E-007		
15	5,46306E-007	3,91110E-007	1,55196E-007		
16	1,02432E-007	6,88661E-008	3,35663E-008		
17	1,80763E-008	1,13509E-008	6,72542E-009		
18	3,01272E-009	1,75737E-009	1,25535E-009		
19	4,75692E-010	2,56351E-010	2,19341E-010		
20	7,13538E-011	3,53296E-011	3,60241E-011		
21	1,01934E-011	4,61156E-012	5,58184E-012		
22	1,39001E-012	5,71390E-013	8,18619E-013		
23	1,81306E-013	6,73411E-014	1,13964E-013		
24	2,26632E-014	7,56305E-015	1,51001E-014		
25	2,71958E-015	8,10821E-016	1,90876E-015		
Différence maximale en valeur absolue			1,69802E-003		

$$n = 200$$

$$p = 0.015$$

$$\lambda = 3$$

Tiré de:

<http://www-timc.imag.fr/Cecile.Amblard/Enseignement/STA230/sortieTP3.pdf>

