



eduscol

Ressources d'accompagnement des anciens programmes

Ressources pour le collège

Organisation et gestion de données au collège

La ressource qui suit a été produite dans le cadre de l'accompagnement des programmes de mathématiques publiés en 2008. A ce titre, elle s'inscrit dans un cadre pédagogique désormais ancien. Néanmoins, elle propose des éléments toujours utiles et pertinents pour aborder le thème « Organisation et gestion de données, fonctions » en vigueur dans le nouveau programme de mathématiques du cycle 4.

mars 2016

Mathématiques

Collège

**- Ressources pour les classes
de 6^e, 5^e, 4^e, et 3^e du collège -**

- Organisation et gestion de données au collège -

Ce document peut être utilisé librement dans le cadre des enseignements et de la formation des enseignants.

Toute reproduction, même partielle, à d'autres fins ou dans une nouvelle publication, est soumise à l'autorisation du directeur général de l'Enseignement scolaire.

Janvier 2007

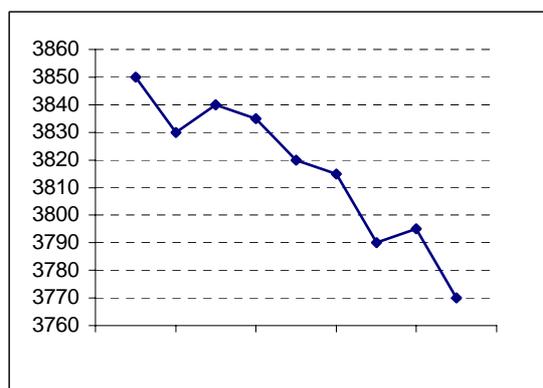
ORGANISATION ET TRAITEMENT DES DONNÉES

1- OBJECTIFS GENERAUX

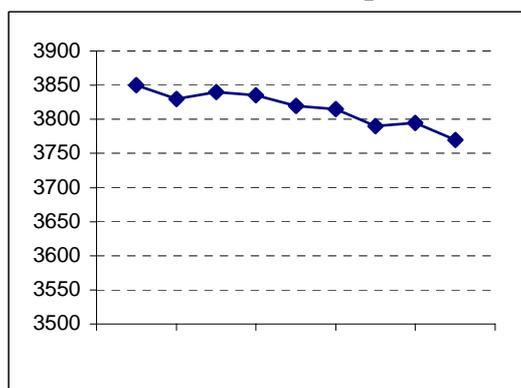
La partie relative à l'organisation et la gestion de données a pour objectif principal de permettre aux élèves de construire et travailler des compétences nécessaires pour recevoir ou produire de l'information chiffrée. Il s'agit d'une part de continuer¹ à initier les élèves de collège à la lecture, à l'utilisation et à la production de tableaux, de représentations graphiques², d'autre part de mettre en place les premiers outils de la statistique descriptive, en particulier la notion de résumé statistique à partir de l'étude de quelques caractéristiques de position et de dispersion. Il s'agit aussi, à travers ces premiers contacts, d'aider les élèves à percevoir que la mise en forme de l'information proposée résulte de choix qui en accentuent ou en atténuent certains aspects et donc de contribuer ainsi au développement de l'esprit critique indispensable dans la vie de tout citoyen.

L'exemple ci-dessous permet de mettre en évidence le caractère subjectif de toute représentation graphique (souvent liée à la plage des données représentée sur les axes) et des interprétations qui pourraient en être tirées.

Un vendredi noir à la Bourse !



L'indice des valeurs est en repli de 2 %...



De même, tout citoyen devrait pouvoir décoder les slogans publicitaires comme par exemple celui, récent, d'un jeu de hasard : "Cent pour cent des gagnants ont tenté leur chance". Il est évident que dire "tous les gagnants ont joué" n'a pas le vernis "scientifique" qui est sensé lui donner de la crédibilité ! Dans un autre registre, celui des sondages d'opinion, il est indispensable de comprendre que 60 % d'avis favorables parmi 75 % de personnes ayant donné une réponse ne constituent pas une majorité absolue de la population tout entière.

Pour donner du sens aux notions étudiées et susciter l'intérêt, les travaux sont conduits à partir d'exemples et en liaison, chaque fois qu'il est possible, avec l'enseignement des autres disciplines. De fait, il est souvent plus pertinent de s'appuyer sur des situations réelles, par exemple sur des activités de relevés (enquêtes, mesurages...) réalisées par les élèves, en particulier dans leur environnement proche. Il est possible aussi d'utiliser des données réelles directement fournies. Les sources de données exploitables sont multiples. Il est ainsi très simple d'accéder à de nombreux aspects des résultats du recensement de 1999, sur le site Internet de l'INSEE, ou à des données chiffrées concernant l'élevage ou la pêche sur le site du ministère de l'Agriculture³.

¹ En effet, à l'école primaire, les élèves ont déjà été mis en situation de prendre de l'information à partir de tableaux, de diagrammes ou de graphiques.

² Le tableur grapheur fait l'objet d'une initiation dès la classe de cinquième et doit être largement utilisé.

³ <http://www.agreste.agriculture.gouv.fr/>

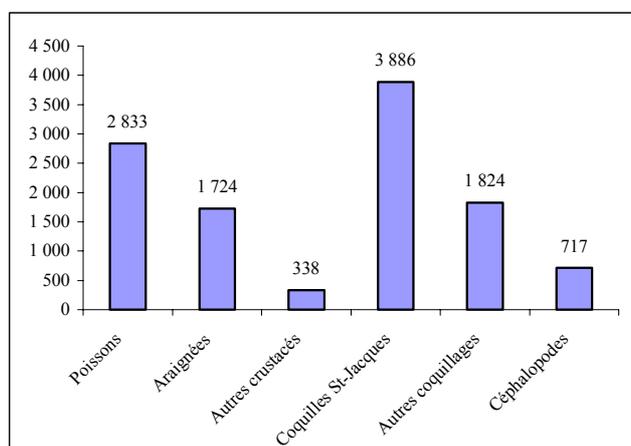
2- LA GESTION DES DONNEES : LES REPRESENTATIONS GRAPHIQUES

De nombreuses formes de représentations graphiques de données peuvent être rencontrées. Les élèves doivent être habitués à exploiter la plupart de ces formes. Les programmes font explicitement référence aux diagrammes en tuyaux d'orgue, en bandes, à secteurs pour les données relatives à un caractère qualitatif, aux diagrammes en bâtons pour les données relatives à un caractère quantitatif discret, aux histogrammes pour les données relatives à un caractère quantitatif continu.

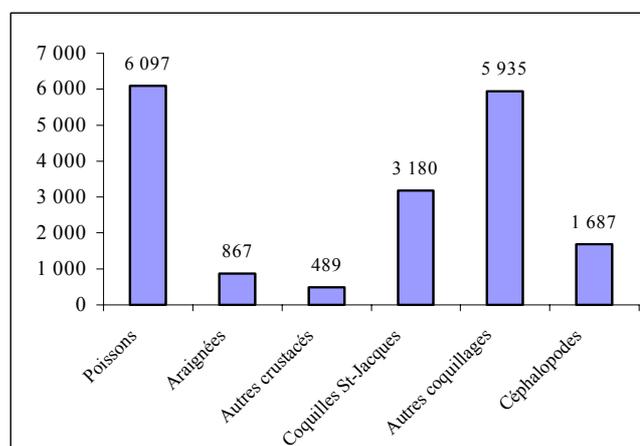
Voici, par exemple, un tableau récapitulatif l'évolution des tonnages et des chiffres d'affaire de la pêche dans le département des Côtes d'Armor de 1991 à 1998.

		1991	1992	1993	1994	1995	1996	1997	1998
Poissons	(tonnes)	2 823	2 833	2 938	3 565	3 903	4 683	5 323	6 097
	(milliers d'euros)	9385	8905	8318	9449	9188	10651	12580	14625
Araignées	(tonnes)	1 588	1 724	1 510	1 332	898	770	831	867
	(milliers d'euros)	3801	4296	3232	3659	2120	1761	2144	2482
Autres crustacés	(tonnes)	307	338	339	429	344	411	435	489
	(milliers d'euros)	1591	1914	2013	2328	1759	2003	1817	2123
Coquilles St-Jacques	(tonnes)		3 886	4 764	5 479	4 501	4 330	4 011	3 180
	(milliers d'euros)	4844	6644	7593	9071	8225	8146	7300	6536
Autres coquillages	(tonnes)	2 321	1 824	1 607	1 212	866	1 701	2 278	5 935
	(milliers d'euros)	2358	1824	1514	1176	1110	1700	2006	3628
Céphalopodes	(tonnes)	978	717	1 317	1 188	1 514	1 477	1 799	1 687
	(milliers d'euros)	1368	1624	2432	2506	2923	2884	5485	4005
Total	(tonnes)	10 024	11 322	12 475	13 205	12 027	13 372	14 677	18 257
	(milliers d'euros)	23347	25207	25102	28189	25325	27145	31332	33399

Pour l'étude des tonnages par catégorie pour des années données (1992 et 1998), l'utilisation d'un diagramme en tuyaux d'orgue est déjà exploitable.



Année 1992



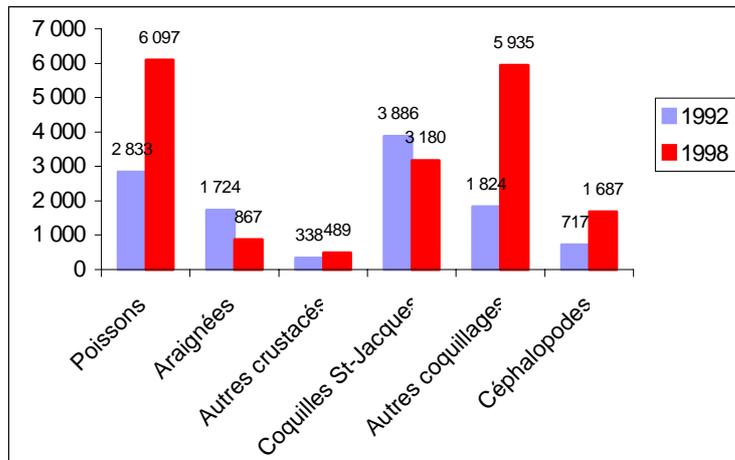
Année 1998

Des réponses simples aux questions suivantes, nécessitant des lectures directes, peuvent être sollicitées dès la sixième :

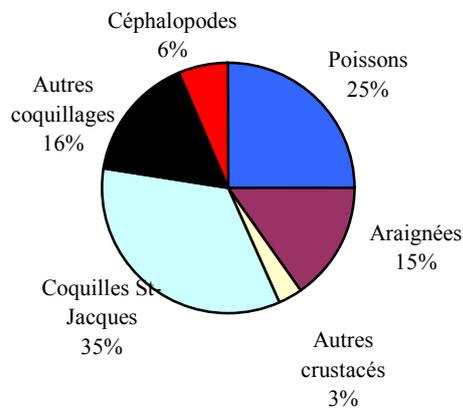
- *Quel est le tonnage de poissons pêchés en 1998 ?*
- *Quelle est la catégorie la plus pêchée en 1992, en 1998 ?*
- *Quelles sont les différences les plus significatives entre les deux années ?*
- ...

Il est à noter que ces réponses peuvent être données aussi à partir du tableau mais l'utilisation du graphique facilite le travail à condition que l'élève soit en mesure d'estimer visuellement certains rapports entre les hauteurs des « tuyaux ».

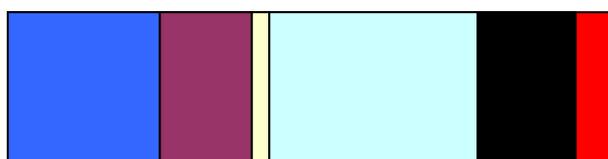
En outre, les questions posées, lors d'une étude de population, peuvent induire le type de graphique retenu. Ainsi, pour la troisième des questions ci-dessus, la représentation des deux années « sur le même graphique » facilite les comparaisons.



Pour réaliser des études relatives, par exemple la place d'une catégorie parmi un tout, le recours aux diagrammes en bandes ou à secteurs est plus adapté. Ils sont souvent associés aux fréquences des différentes catégories. Ainsi la pêche, par catégorie, en 1992, peut se résumer par le diagramme circulaire suivant :



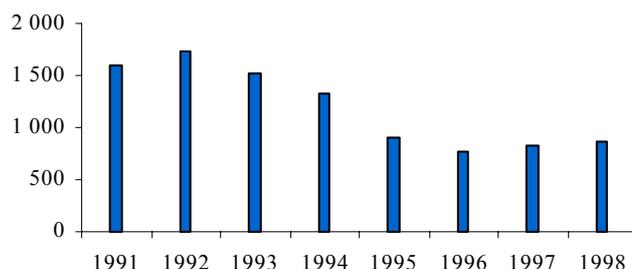
La représentation par un diagramme en bandes obéit à la même démarche. Il s'agit de découper la surface d'un rectangle en sous-surfaces dont les aires sont proportionnelles aux effectifs de chaque catégorie (c'est-à-dire dont les longueurs sont proportionnelles aux effectifs ou aux fréquences de chaque catégorie).



La prise d'information à partir de ces représentations s'appuie essentiellement sur la capacité à estimer visuellement les rapports partie/tout ou partie a /partie b et inversement, de telles constructions contribuent à développer cette capacité chez les élèves.

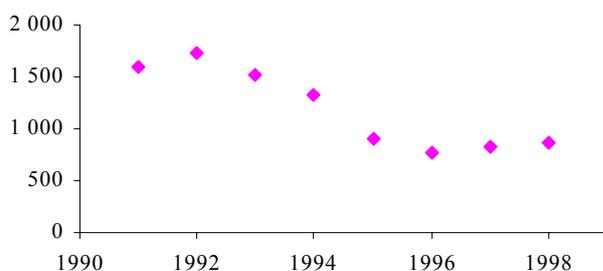
L'évolution du tonnage de la pêche à l'araignée au cours de la période 1991-1998 est une donnée à caractère quantitatif discret, comme la plupart des séries chronologiques. L'utilisation d'un diagramme en bâtons⁴ est ici appropriée.

Evolution du tonnage de la pêche des araignées
entre 1991 et 1998

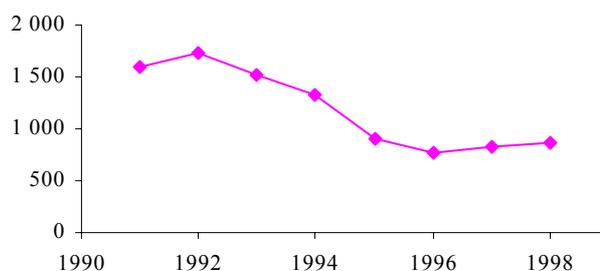


Il faut remarquer que des représentations graphiques voisines sont souvent utilisées : par exemple, un nuage de points ou une courbe représentative. Il importe alors d'indiquer aux élèves le lien avec la représentation standard et de leur faire comprendre les différences d'implicites qu'elles introduisent⁵.

Evolution du tonnage de la pêche des araignées
entre 1991 et 1998



Evolution du tonnage de la pêche des araignées
entre 1991 et 1998



Lorsque les valeurs possibles pour un caractère quantitatif discret sont très nombreuses, par exemple les notes moyennes (arrondies au dixième) d'un groupe d'élèves, il devient difficile voire impossible d'utiliser un diagramme en bâtons. Il convient alors de réaliser des regroupements par classes et d'avoir recours à un histogramme⁶ pour représenter les données. Il en est de même pour les données qui peuvent prendre toutes les valeurs d'un intervalle réel, par exemple la taille des

⁴ Les logiciels les plus fréquemment utilisés ne permettent pas de réaliser des diagrammes en bâtons. Il faut faire un diagramme en tuyaux d'orgue et réduire la largeur des barres en choisissant un écartement maximum entre deux barres.

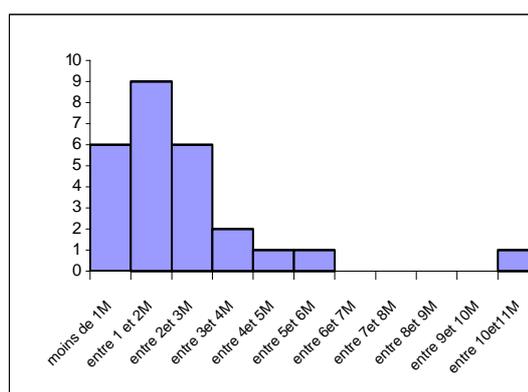
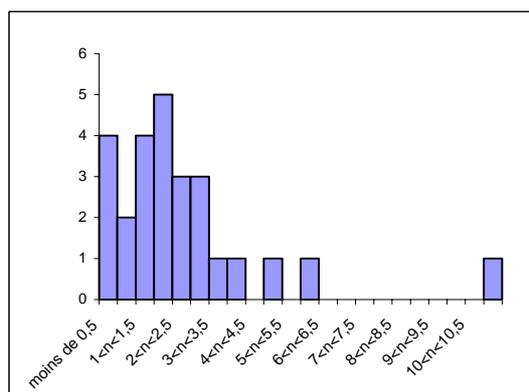
⁵ Dans la représentation de droite, le fait de relier les points ne correspond à aucune réalité concrète ou théorique.

Il s'agit simplement d'avoir un aperçu plus "parlant" de l'évolution étudiée.

⁶ C'est à partir de la classe de cinquième que sont introduits les histogrammes dans le programme de mathématiques

nouveaux-nés de l'année 2004 ou plus généralement tout caractère faisant l'objet d'une mesure physique.

Le choix de l'amplitude des classes dépend de la nature du problème étudié. Pour étudier les irrégularités d'une distribution, les intervalles doivent être assez petits. Si c'est la forme générale qui présente de l'intérêt, les intervalles sont plus grands. Ainsi, l'exemple ci-dessous, construit à partir de tableaux de l'INSEE (recensement 1999), décrit le nombre de régions de France suivant le nombre d'habitants. L'amplitude des classes est 0,5 million pour l'histogramme de gauche, de 1 million pour celui de droite. Il est possible de constater l'existence de quatre régions "peu peuplées" sur l'histogramme de gauche, ce que ne révèle pas celui de droite. Les programmes précisent que les exemples étudiés se limitent au cas de classes d'égale amplitude⁷. L'histogramme se lit alors comme un diagramme en bâtons.



Le choix de l'amplitude des classes joue donc un rôle fondamental car certaines caractéristiques importantes peuvent être gommées par le choix d'une amplitude trop grande.

Toutes les représentations précédentes sont rencontrées dès la classe de sixième⁸, voire au niveau de l'école primaire, dans de nombreuses disciplines. A ce niveau, il n'est pas encore question de série statistique. Les données, sur lesquelles le travail s'effectue, peuvent ou non constituer les valeurs prises par un caractère (quantitatif ou non) défini sur une population. Dans de nombreuses situations réelles, que les élèves peuvent rencontrer, notamment dans les autres disciplines, il est difficile, voire impossible, de définir une population au sens statistique du terme mais le recours aux outils de représentation précédents est néanmoins légitime.

3- LE PASSAGE A LA STATISTIQUE

Ce sont les problèmes à résoudre et les calculs éventuels qui orientent le choix d'un type d'organisation et de représentation et introduisent alors la nécessité d'un traitement statistique. L'exemple suivant, construit à partir d'observations météorologiques locales (plan d'eau au large d'un port de la côte nord de la Bretagne), permet d'illustrer les notions statistiques de population, de caractère qualitatif ou quantitatif et, en s'appuyant sur les diverses représentations évoquées au paragraphe précédent, est sensé souligner le passage de la pure gestion de données au domaine de la Statistique.

Le recueil des données, réalisé jour par jour par une école de voile afin de mieux connaître son plan d'eau, a permis d'obtenir le tableau suivant.

⁷ Sauf éventuellement pour les classes extrêmes.

⁸ Il s'agit en sixième essentiellement de lecture et d'interprétation. La construction de telles représentations par les élèves relève de la cinquième.

Observation du vent- Eté 2005

Chaque jour, un relevé météorologique est réalisé en début d'après midi..

La vitesse indiquée est la moyenne donnée par l'anémomètre lors d'une mesure durant 1 minute.

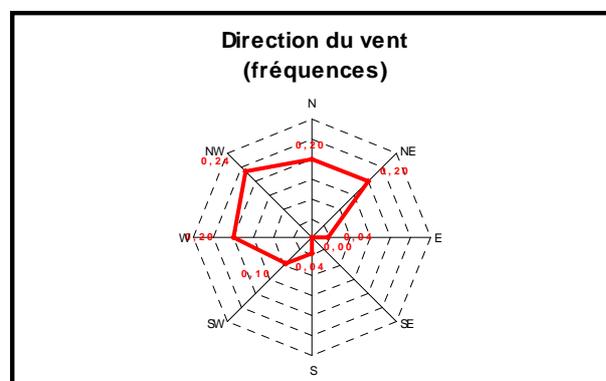
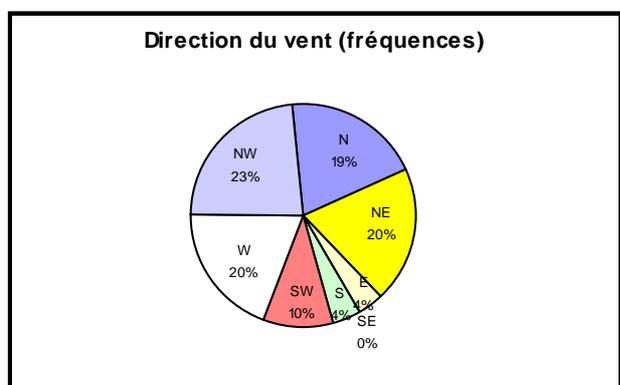
date	direction observée	vitesse mesurée en nœud	Beaufort	série ordonnée	vitesse croissantes
09/07/2005	W	4,3	2		0,5
10/07/2005	NW	5,9	2		1,1
11/07/2005	NW	7	3		2,2
12/07/2005	NE	9,8	3		2,5
13/07/2005	N	2,8	1		2,8
14/07/2005	NE	1,1	1		2,8
15/07/2005	NE	6,2	2		3
16/07/2005	NE	11	4		4,1
17/07/2005	NW	5,5	2		4,2
18/07/2005	W	7,3	3		4,3
19/07/2005	W	7,5	3		4,3
20/07/2005	NW	8	3		4,5
21/07/2005	N	15,6	4		4,8
22/07/2005	N	7,4	3		4,8
23/07/2005	S	4,2	2		5,1
24/07/2005	SW	11,7	4		5,5
25/07/2005	W	6,8	2		5,5
26/07/2005	SW	0,5	0		5,9
27/07/2005	S	2,8	1		6
28/07/2005	SW	3	1		6,2
29/07/2005	NW	6,7	2		6,4
30/07/2005	W	6	2		6,5
31/07/2005	W	6,5	2		6,5
01/08/2005	N	9,2	3		6,7
02/08/2005	NW	5,5	2		6,8
03/08/2005	N	15,2	4		7
04/08/2005	NW	4,8	2		7
05/08/2005	W	7	3		7,3
06/08/2005	N	10,7	3		7,4
07/08/2005	NE	13,2	4		7,5
08/08/2005	NE	4,3	2		8
09/08/2005	NE	5,1	2		8
10/08/2005	E	4,5	2		8,6
11/08/2005	N	8,6	3		9,2
12/08/2005	NW	12,1	4		9,6
13/08/2005	W	6,5	2		9,7
14/08/2005	NW	18,1	5		9,8
15/08/2005	NE	8	3		10,1
16/08/2005	NE	10,1	3		10,7
17/08/2005	E	6,4	2		11
18/08/2005	W	4,1	2		11,2
19/08/2005	NW	20,4	5		11,7
20/08/2005	N	13,2	4		11,8
21/08/2005	N	12,3	4		12,1
22/08/2005	NW	2,5	1		12,3
23/08/2005	N	11,2	4		13,2
24/08/2005	SW	9,6	3		13,2
25/08/2005	SW	11,8	4		15,2
26/08/2005	W	9,7	3		15,6
27/08/2005	W	2,2	1		18,1
28/08/2005	NE	4,8	2		20,4
moyenne		7,8176			

La population est ici constituée des jours d'observation. Il est alors possible, entre autres, d'étudier la direction du vent (caractère qualitatif) ou bien sa « force » (c'est à dire sa vitesse, caractère quantitatif). Le traitement statistique s'effectue à partir du moment où on « s'affranchit » des individus (les jours datés ici) pour s'intéresser à la façon dont ces individus se distribuent vis à vis du caractère observé : toute l'information, relative à ce caractère, considérée comme utile est contenue dans la distribution d'effectifs.

Dans l'exemple précédent, si l'étude porte sur la direction des vents, les résultats peuvent être synthétisés dans un tableau du type suivant :

Direction	N	NE	E	SE	S	SW	W	NW
Nombre de jours	10	10	2	0	2	5	10	12
Fréquence ⁹ (par excès)	0,20	0,20	0,04	0,00	0,04	0,10	0,20	0,24

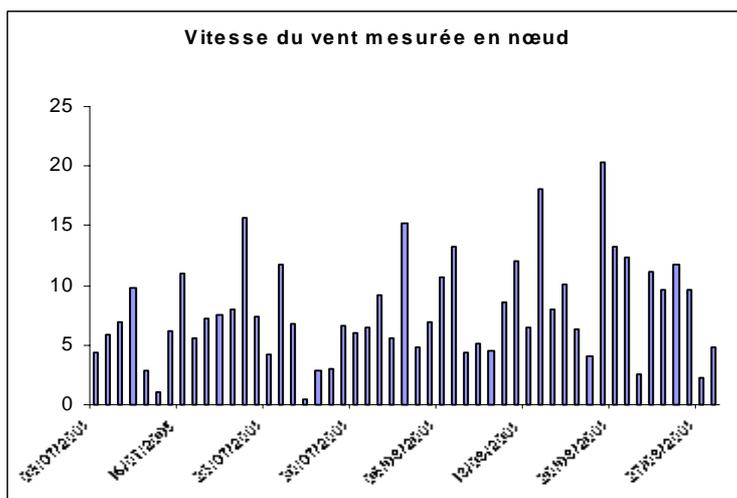
Les différentes représentations graphiques évoquées précédemment sont disponibles. Dans le cas présent, un diagramme circulaire est approprié. Une autre représentation, le diagramme en toile d'araignée, peut aussi bien rendre compte sur le plan visuel de la distribution du caractère observé.



A partir des graphiques, aussi bien que sur le tableau, il est possible de dégager le fait que les vents de secteur SUD (SW, S, SE) sont très peu fréquents, ce qui souligne la puissance de suggestion d'une représentation visuelle.

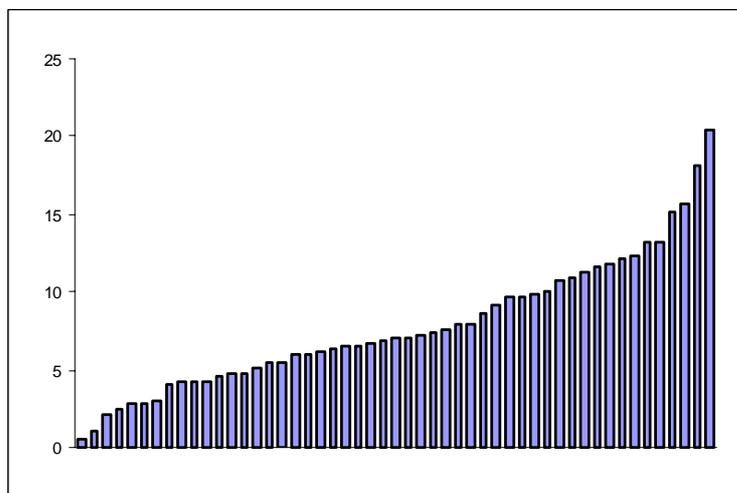
⁹ La gestion des fréquences serait plus simple s'il n'y avait que 50 données.

Dans le cas de l'étude des vitesses observées, un premier diagramme en bâtons (basique) peut représenter la série des vitesses de vent observées, jour après jour. Cette représentation n'est pas facile à exploiter sous cette forme.



Les responsables de l'école de voile s'intéressent au nombre de jours où il est impossible de faire sortir les stagiaires pour des raisons de sécurité. Le travail porte alors, par exemple, sur le nombre de jours où le vent a dépassé un certain seuil.

Une simple réorganisation des données (suivant les vitesses croissantes), à l'aide du tableur, sur le tableau précédent (page 6) permet de mettre en évidence médiane et quartiles. Elle correspond aussi à une réorganisation graphique.



Il est alors possible de rendre compte des observations sous différents aspects comme par exemple " la moitié du temps (les $\frac{3}{4}$ du temps), le vent a été inférieur à 7 nœuds (10,7 nœuds) "...

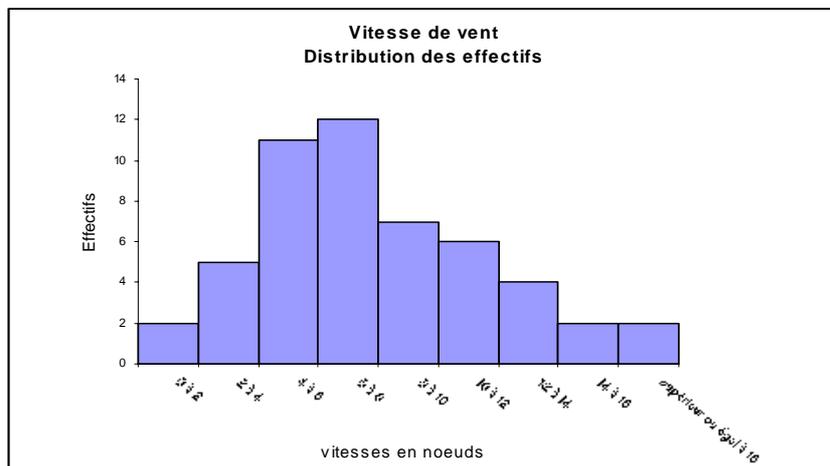
Pour répondre à d'autres problématiques¹⁰, par exemple " un vent de vitesse supérieure à 12 nœuds est-il un vent « fort » sur ce plan d'eau ? " en lien avec le domaine de la prévision (donc celui des probabilités : " Combien de chances a-t-on d'avoir un vent de 12 nœuds ou plus ? "), il est alors nécessaire d'approfondir l'étude en s'intéressant au rapport entre le nombre de jours où le vent dépasse les 12 nœuds et le nombre total de jours d'observation, c'est-à-dire à la fréquence de cet

¹⁰ Problématiques qui conditionnent pour le club l'organisation des activités sur l'eau

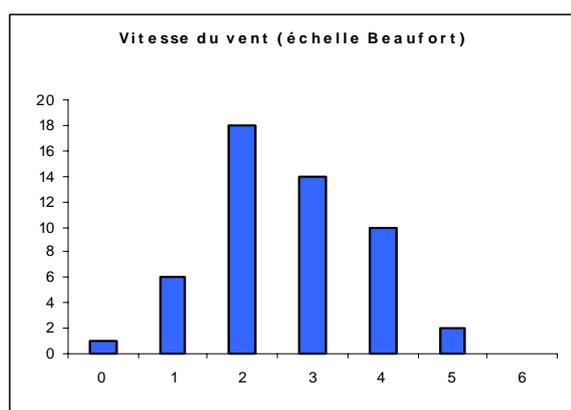
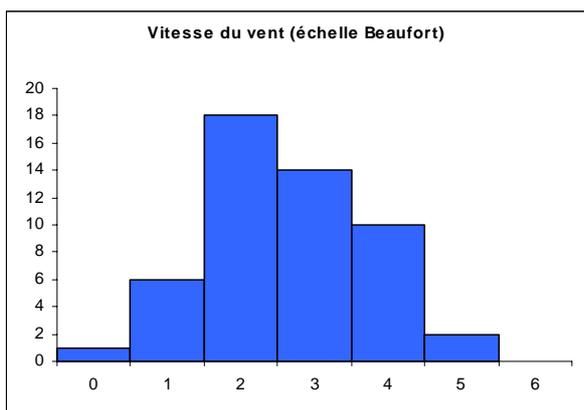
événement et plus globalement à la distribution des fréquences pour construire un modèle de loi de probabilité (approche fréquentiste)¹¹.

Dans le cas présent, la distribution des fréquences des vitesses observées (valeurs discrètes et nombreuses) n'est pas directement facilement exploitable. Le travail est donc plus complexe du fait de la nature quantitative continue du caractère observé. Il consiste à regrouper les données par classes et à les représenter à l'aide d'un histogramme.

Dans le cas de l'étude du vent, le choix d'intervalles d'amplitude 2 (nœuds), permet d'obtenir la représentation ci-dessous.



Remarque: la météorologie marine internationale utilise habituellement l'échelle Beaufort. Il est possible de la considérer comme un regroupement par classes¹² (puisque à un chiffre (degré) de l'échelle correspond un intervalle de nombres réels) et de garder ainsi le caractère quantitatif sous-jacent. Il est aussi envisageable de considérer que les chiffres de l'échelle Beaufort permettent de décrire un caractère qualitatif. C'est d'ailleurs ce qui est souvent réalisé dans le descriptif des états du vent correspondant : calme, très légère brise, légère brise, petite brise, jolie brise, bonne brise, vent frais,... Dans ces conditions, les diagrammes (en tuyaux d'orgue, circulaire) sont tout aussi pertinents.



Mais, la représentation de gauche est à éviter. Elle peut entretenir la confusion avec un histogramme.

¹¹ Il importe particulièrement de faire la différence entre la distribution de fréquences observée et la loi de probabilité déduite. Le modèle construit à partir de 51 observations serait très rustique. Les observations réalisées sur 3 périodes estivales successives, d'une cinquantaine de jours chacune, mettent en évidence une grande fluctuation des échantillons. La fluctuation d'échantillonnage sera étudiée en seconde.

¹² Ce regroupement ne se fait pas suivant des classes de taille constante.

3- LES PREMIERES NOTIONS DE RESUME STATISTIQUE

3.1• Effectifs et fréquences

La notion de fréquence est introduite en classe de cinquième. Son utilisation peut être légitimée par des questions de comparaison de sous-populations ayant un caractère donné dans des populations d'effectifs différents. A partir de là, le premier objectif est de savoir calculer des fréquences dans un contexte donné. Diverses écritures peuvent être utilisées pour désigner une fréquence mais, le plus souvent, une valeur décimale exacte ou approchée ou un pourcentage permettent de mieux fixer les idées. C'est ainsi que, dans l'exemple de l'étude du vent, la fréquence du vent de Nord Est est donnée sous la forme 20 % ou 0,20 plutôt que $\frac{10}{51}$.

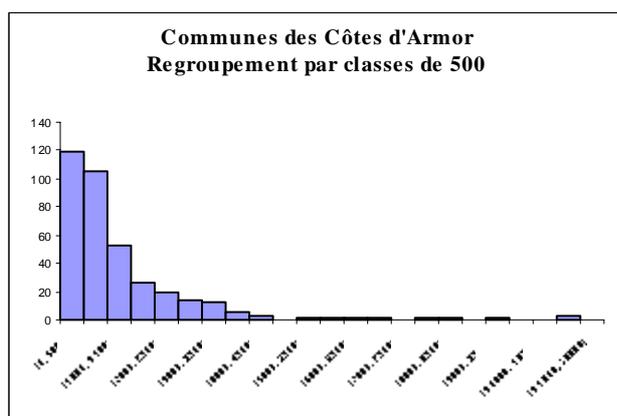
Dans un deuxième temps, la notion de fréquence peut être utilisée dans quelques exemples de comparaison de deux distributions d'une même variable qualitative. Il importe alors de choisir des contextes dans lesquels cette comparaison a un sens.

3.2• Moyenne, moyenne pondérée

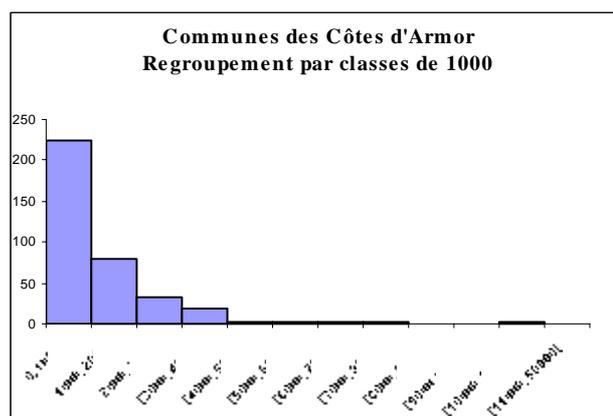
Les diagrammes et les histogrammes sont des outils de description des données assez complets mais leur mise en œuvre est parfois lourde. Pour effectuer des travaux plus globaux ou des études comparatives, il s'avère nécessaire de synthétiser davantage l'information.

La moyenne est la première caractéristique de position étudiée. Les élèves connaissent cette notion dans la mesure où elle est très présente dans leur scolarité¹³. Ils doivent approfondir leurs connaissances à son sujet : différents procédés de calcul, compréhension des effets de regroupements (la moyenne des moyennes partielles n'est pas forcément égale à la moyenne), dépendance des valeurs extrêmes, fait qu'une même moyenne peut résumer des ensembles de données très différents (par exemple : forte concentration autour de la moyenne ou forte dispersion par rapport à celle-ci), à partir de situations variées et significatives au delà du classique travail sur les notes obtenues par les élèves.

Le recours à des regroupements en classes pour l'estimation d'une moyenne¹⁴ n'est pas un objectif des programmes. Il peut être entrepris sur un exemple pour faire constater d'une part la perte d'information et d'autre part le confort et la fiabilité qu'apporte l'utilisation d'un tableur pour effectuer un tel calcul.



Estimation de la moyenne : $m_{500} = 1409$



Estimation de la moyenne : $m_{1000} = 1444$

La moyenne donnée par un calcul direct au tableur est 1458¹⁵.

¹³ Moyenne des notes trimestrielles calculée le plus souvent comme moyenne arithmétique des notes aux contrôles.

¹⁴ En utilisant les milieux des classes, affectés de l'effectif de la classe correspondante.

¹⁵ L'exemple montre aussi que, contrairement à une idée répandue, une amplitude plus petite ne garantit pas une meilleure estimation.

3.3• Médiane, quartiles

La médiane est, comme la moyenne, un indicateur de tendance centrale.

La définition qui est retenue en collège pour la médiane d'une série est celle qui est adoptée dans le programme de seconde. Elle s'appuie sur la pratique :

Médiane (empirique) : *La série des données est ordonnée par ordre croissant. Si la série est de taille impaire ($2n+1$), la médiane est la valeur du terme de rang $n+1$. Si la série est de taille paire ($2n$), la médiane est la demi-somme des valeurs des termes de rang n et $n+1$.*

D'autres définitions sont parfois utilisées ; par exemple, la médiane est le deuxième quartile¹⁶. Dans la pratique statistique, ces différences n'ont pas d'importance. Pour les élèves, connaître la signification de la médiane en terme de position est l'objectif principal. La détermination de la médiane nécessite le classement des données, ce qui n'est pas le cas pour le calcul de la moyenne. De plus, contrairement à la moyenne, la médiane n'est pas sensible aux valeurs extrêmes, ce qui est mis en évidence sur des exemples. La position relative de la médiane et de la moyenne d'une série peut être interprétée quand cela est significatif. Ainsi des expressions comme « la moyenne des salaires est... » et « la médiane des salaires est ... » doivent pouvoir être traduites par les élèves sous d'autres formes, par exemple : « Avec la masse des salaires distribués, si chacun recevait le même salaire, celui-ci serait de ... », « La moitié de la population gagne plus de ... et l'autre moitié moins de ... ».

Pour mieux comprendre la notion de médiane, il est utile de mettre en évidence, sur quelques exemples, d'autres caractéristiques de position : les premier et troisième quartiles.

Pour mémoire, les définitions concernant les quartiles sont les suivantes :

Premier quartile (empirique) : *c'est le plus petit élément q des valeurs des termes de la série, tel qu'au moins 25 % des données sont inférieures ou égales à q .*

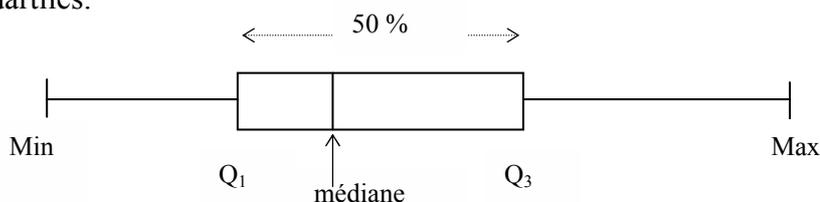
Troisième quartile (empirique) : *c'est le plus petit élément q' des valeurs des termes de la série, tel qu'au moins 75 % des données sont inférieures ou égales à q' .*

3.4• Etendue

Le seul paramètre relatif à la dispersion¹⁷ d'une série de données dans les programmes de collège est l'étendue. Ce premier élément concernant la notion de dispersion est rudimentaire. Il présente un inconvénient : sa très grande sensibilité aux extrêmes. La détermination des quartiles peut alors compléter la connaissance de la distribution, en considérant l'intervalle interquartile (voir schéma ci-dessous).

Une fois déterminés ces différents paramètres, il est possible de donner un premier résumé statistique d'une série.

Remarque : Dans de nombreuses disciplines, il est d'usage de présenter ce résumé sous une forme graphique : le diagramme en boîte (ou à moustaches ou de Tuckey). Comme les histogrammes, les diagrammes en boîte représentent graphiquement une série de données. Au lieu de partager l'ensemble des valeurs possibles en intervalles d'amplitude constante, on le partage en segments qui contiennent une proportion fixée des valeurs de la série. La configuration la plus classique s'appuie simplement sur les quartiles.



¹⁶ En théorie, on définit, pour toute série numérique de données à valeur dans un intervalle I , la fonction quantile Q , de $[0,1]$ dans I , par : $Q(t) = \inf \{x, F(x) \geq t\}$, où $F(x)$ désigne la fréquence des éléments de la série inférieurs ou égaux à x . La médiane est alors $Q(0,50)$.

¹⁷ L'intérêt de la notion de dispersion peut se dégager de la nécessité de distinguer deux séries de même tendance centrale.

Les diagrammes en boîtes ne font l'objet d'aucune étude spécifique au collège. Cependant, pour quelques exemples, il peut être intéressant de les faire matérialiser pour mieux visualiser la distribution des valeurs et notamment comparer plusieurs répartitions comme dans l'exemple de l'étude de la population en Bretagne (cf. annexe 2).

4- LES INTERACTIONS AVEC D'AUTRES DOMAINES D'ETUDE

4.1 • Liens avec le calcul

A l'évidence, le premier domaine des programmes de mathématiques qui entre en interaction avec la représentation et le traitement des données est celui des nombres et du calcul. Le classement des données, la détermination des différentes caractéristiques, des fréquences... sont des occasions de manipuler les nombres entiers et décimaux, de travailler sur les diverses représentations d'un même nombre et d'organiser des calculs. Les calculs induits par les problèmes posés sont élémentaires (quatre opérations) et restent ainsi accessibles à la plupart des élèves. C'est aussi l'occasion, quand la situation s'y prête, de pratiquer le calcul mental en lui donnant un objectif précis (ordre de grandeur, anticipation des résultats...). D'un autre point de vue, la nécessité (voulue) de traiter des situations réelles présentant des grands effectifs de données limite la pratique, dans ce domaine, du calcul "à la main". Le recours au calcul instrumenté est alors naturellement mis en œuvre. Il n'est évidemment pas inutile, cependant, d'aborder, sans instrument de calcul, des situations plus simples lors de la mise en place des notions pour en renforcer la compréhension.

L'utilisation du tableur-grapheur est intimement liée au travail de traitement des données dans la mesure où il permet non seulement d'exécuter les différents calculs nécessaires dans des conditions favorables mais aussi d'obtenir directement les représentations graphiques souhaitées. C'est donc une nécessité de débiter l'apprentissage de cet outil dès la cinquième (le niveau auquel on commence à construire de l'information) !

4.2 • Liens avec la proportionnalité

La proportionnalité intervient très souvent dans le travail de traitement des données. C'est ainsi que la graduation d'un axe prend appui sur la proportionnalité des distances entre deux points et des écarts entre les deux valeurs qu'ils représentent. De même, la détermination des fréquences de différents caractères d'une même série fait intervenir la proportionnalité à leurs effectifs. L'élaboration de diagrammes circulaires ou en bande est une occasion particulière de faire fonctionner la proportionnalité dans la détermination des angles ou des longueurs. Il peut être aussi utile de faire remarquer, dans un histogramme, la proportionnalité de l'aire¹⁸ d'un rectangle et de la fréquence correspondante. Il convient donc, à chaque occasion, d'explicitier la présence et l'utilisation de la proportionnalité et de travailler ainsi à consolider la cohérence interne des programmes.

4.3 • Liens avec les autres disciplines

L'interaction de la partie "Organisation et gestion de données" avec les autres disciplines enseignées au collège se fait essentiellement sous deux formes. Dans un sens, les savoirs et savoir-faire construits dans le cadre de l'enseignement des mathématiques sont opérationnalisés dans des études spécifiques à la discipline concernée. La plupart des compétences travaillées en mathématique sont mobilisables : lecture de tableaux et lecture graphique, traitements calculatoires et graphiques

¹⁸ Même si les histogrammes en classes inégales ne sont pas abordés au collège.

divers, élaboration d'un résumé statistique... C'est le cas en particulier des disciplines expérimentales : Sciences de la vie et de la Terre et Physique-Chimie dans lesquelles les relevés d'observations ou de mesures nécessitent un traitement statistique, mais aussi de la géographie qui fait un usage important des représentations graphiques et des statistiques, ou de la technologie... Dans l'autre sens, les disciplines peuvent fournir aux mathématiques les exemples sur lesquels les notions à mettre en évidence sont dégagées ou exploitées.

L'étude de certains thèmes de convergence propres à l'ensemble des disciplines scientifiques : météorologie, santé, sécurité, environnement offre une occasion particulièrement pertinente de mettre en œuvre ces implications mutuelles.