

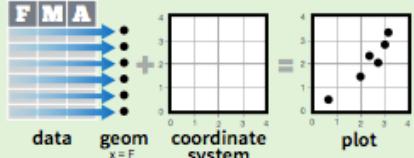
Les Graphiques avec ggplot2

Aide mémoire

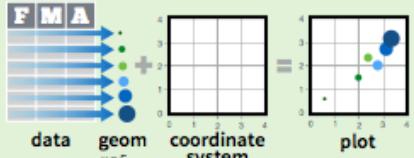


Les Bases

ggplot2 est basé sur "grammar of graphics", le principe est que vous pouvez construire tous les graphiques à partir d'un même petit nombre d'éléments : un jeu de données, un ensemble de geoms (repères visuels) qui représentent les points de données et un système de coordonnées.



Pour afficher les valeurs de données, il faut utiliser les variables du jeu de données en tant que propriétés esthétiques du geom dans size, color, x et y.



Les graphs se construisent avec **ggplot()** ou **qplot()**

propriétés esthétiques **données** **geom**

qplot(x = cty, y = hwy, color = cyl, data = mpg, geom = "point")
génère un graphique complet à partir des données, du geom et des propriétés esthétiques passés en paramètres et intègre de nombreux paramètres par défaut très utiles.

ggplot(data = mpg, aes(x = cty, y = hwy))

initialise un graphique à compléter en ajoutant des calques. Il n'y a pas de calques par défaut, mais cela permet plus de contrôle que qplot().

données

`ggplot(mpg, aes(hwy, cty)) +
 geom_point(aes(color = cyl)) +
 geom_smooth(method = "lm") +
 coord_cartesian() +
 scale_color_gradient() +
 theme_bw()`

ajout de calques avec +
calque = geom + stat par défaut + calque spécifique
éléments complémentaires

On ajoute un calque à un graphique avec une fonction **geom_***() ou **stat_***(). Chacun génère un geom, un ensemble de propriétés esthétiques et un claque statistique.

last_plot()

Renvoie le dernier graphique

ggsave("plot.png", width = 5, height = 5)

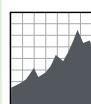
Sauvegarde dans l'espace de travail le dernier graphique affiché dans un fichier "plot.png" de dimension 5' x 5'. Le type de fichier généré dépend directement de l'extension de nom de fichier indiquée.

Geoms - Utiliser un geom pour représenter les points de données, utiliser les propriétés esthétiques du geom pour représenter des variables. Chaque fonction renvoie un calque.

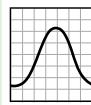
Une variable

Continue

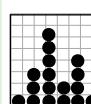
`a <- ggplot(mpg, aes(hwy))`



a + geom_area(stat = "bin")
x, y, alpha, color, fill, linetype, size
b + geom_area(aes(y = ..density..), stat = "bin")



a + geom_density(kernel = "gaussian")
x, y, alpha, color, fill, linetype, size, weight
b + geom_density(aes(y = ..county..))



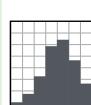
a + geom_dotplot()

x, y, alpha, color, fill



a + geom_freqpoly()

x, y, alpha, color, linetype, size
b + geom_freqpoly(aes(y = ..density..))

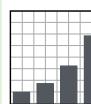


a + geom_histogram(binwidth = 5)

x, y, alpha, color, fill, linetype, size, weight
b + geom_histogram(aes(y = ..density..))

Discrète

`b <- ggplot(mpg, aes(fl))`



b + geom_bar()

x, alpha, color, fill, linetype, size, weight

Éléments graphiques

`c <- ggplot(map, aes(long, lat))`



c + geom_polygon(aes(group = group))

x, y, alpha, color, fill, linetype, size

`d <- ggplot(economics, aes(date, unemploy))`

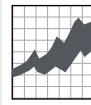


d + geom_path(lineend = "butt",

`linejoin = "round", linemitre = 1)`

x, y, alpha, color, linetype, size
d + geom_ribbon(aes(ymin = unemploy - 900,

`ymax = unemploy + 900))`



x, ymax, ymin, alpha, color, fill, linetype, size

`e <- ggplot(seals, aes(x = long, y = lat))`



e + geom_segment(aes(

`xend = long + delta_long,`

`yend = lat + delta_lat))`

x, xend, y, yend, alpha, color, linetype, size



e + geom_rect(aes(xmin = long, ymin = lat,

`xmax = long + delta_long,`

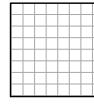
`ymax = lat + delta_lat))`

xmax, xmin, ymax, ymin, alpha, color, fill, linetype, size

Deux variables

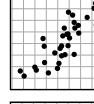
X Continue, Y Continue

`f <- ggplot(mpg, aes(cty, hwy))`



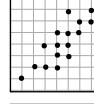
f + geom_blank()

(Utile pour étendre les limites)



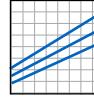
f + geom_jitter()

x, y, alpha, color, fill, shape, size



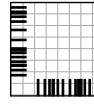
f + geom_point()

x, y, alpha, color, fill, shape, size



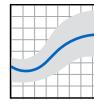
f + geom_quantile()

x, y, alpha, color, linetype, size, weight



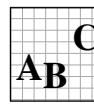
f + geom_rug(sides = "bl")

alpha, color, linetype, size



f + geom_smooth(model = lm)

x, y, alpha, color, fill, linetype, size, weight



f + geom_text(aes(label = cty))

x, y, label, alpha, angle, color, family, fontface, hjust, lineheight, size, vjust

Distribution bivariée continue

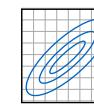
`i <- ggplot(movies, aes(year, rating))`



i + geom_bin2d(binwidth = c(5, 0.5))

xmax, xmin, ymax, ymin, alpha, color, fill,

linetype, size, weight



i + geom_density2d()

x, y, alpha, colour, linetype, size

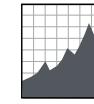


i + geom_hex()

x, y, alpha, colour, fill size

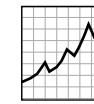
Fonction continue

`j <- ggplot(economics, aes(date, unemploy))`



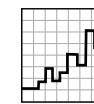
j + geom_area()

x, y, alpha, color, fill, linetype, size



j + geom_line()

x, y, alpha, color, linetype, size



j + geom_step(direction = "hv")

x, y, alpha, color, linetype, size

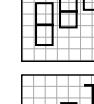
Marge d'erreur

`df <- data.frame(grp = c("A", "B"), fit = 4:5, se = 1:2)`



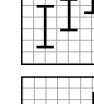
k + geom_crossbar(fatten = 2)

x, y, ymax, ymin, alpha, color, fill, linetype, size



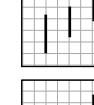
k + geom_errorbar()

x, ymax, ymin, alpha, color, linetype, size, width (also **geom_errorbarh()**)



k + geom_linerange()

x, ymin, ymax, alpha, color, linetype, size



k + geom_pointrange()

x, y, ymin, ymax, alpha, color, fill, linetype, shape, size

Cartographie

`data <- data.frame(meurtre = USArests$Murder,`

`etat = tolower(rownames(USArests)))`

`map <- map_data("etat")`

`l <- ggplot(data, aes(fill = meurtre))`



l + geom_map(aes(map_id = etat), map = map) +

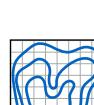
`expand_limits(x = map$long, y = map$lat)`

map_id, alpha, color, fill, linetype, size

Trois Variables

`seals$z <- with(seals, sqrt(delta_long^2 + delta_lat^2))`

`m <- ggplot(seals, aes(long, lat))`



m + geom_raster(aes(fill = z), hjust = 0.5,

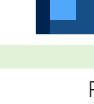
vjust = 0.5, interpolate = FALSE)

x, y, alpha, fill (**rapide**)



m + geom_contour(aes(z = z))

x, y, z, alpha, colour, linetype, size, weight

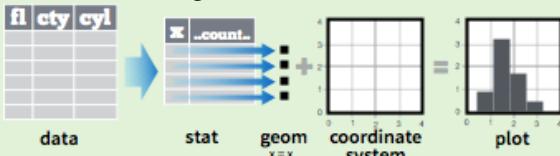


m + geom_tile(aes(fill = z))

x, y, alpha, color, fill, linetype, size (**lent**)

Stats - une autre façon de fabriquer un calque

Certains graphiques représentent une transformation du jeu de données original. Il est possible d'utiliser un calque statistique pour choisir une transformation courante à représenter, ex : `a + geom_bar(stat = "bin")`



Chaque calque statistique crée des variables supplémentaires qui modifient l'affichage. Ces variables utilisent la syntaxe commune : `..nom..`

Les fonctions stat et geom combinent chacune un stat et un geom pour produire un calque, par exemple :

```
stat_bin(geom="bar") revient à geom_bar(stat="bin")
```

fonction stat **calque spécifique** **variable créée par transformation**

i + stat_density2d(aes(fill = ..level..), geom = "polygon", n = 100)

geom du calque **Paramètre de stat**

```
a + stat_bin(binwidth = 1, origin = 10)      Distribution 1D
```

```
x, y | ..count.,..ncount.,..density.,..ndensity..
```

```
a + stat_bindot(binwidth = 1, binaxis = "x")
```

```
x, y | ..count.,..ncount..
```

```
a + stat_density(adjust = 1, kernel = "gaussian")
```

```
x, y | ..count.,..density.,..scaled..
```

```
f + stat_bin2d(bins = 30, drop = TRUE)      Distribution 2D
```

```
x, y, fill | ..count.,..density..
```

```
f + stat_binhex(bins = 30)
```

```
x, y, fill | ..count.,..density..
```

```
f + stat_density2d(contour = TRUE, n = 100)
```

```
x, y, color, size | ..level..
```

```
m + stat_contour(aes(z = z))      3 Variables
```

```
x, y, z, order | ..level..
```

```
m + stat_spoke(aes(radius = z, angle = z))
```

```
angle, radius, x, xend, y, yend | ..x.,..xend.,..y.,..yend..
```

```
m + stat_summary_hex(aes(z = z), bins = 30, fun = mean)
```

```
x, y, z, fill | ..value..
```

```
m + stat_summary2d(aes(z = z), bins = 30, fun = mean)
```

```
x, y, z, fill | ..value..
```

```
g + stat_boxplot(coef = 1.5)      Comparaisons
```

```
x, y | ..lower.,..middle.,..upper.,..outliers..
```

```
g + stat_ydensity(adjust = 1, kernel = "gaussian", scale = "area")
```

```
x, y | ..density.,..scaled.,..count.,..n.,..violinwidth.,..width..
```

```
f + stat_ecdf(n = 40)      Fonctions
```

```
x, y | ..x.,..y..
```

```
f + stat_quantile(quantiles = c(0.25, 0.5, 0.75), formula = y ~ log(x), method = "rq")
```

```
x, y | ..quantile.,..x.,..y..
```

```
f + stat_smooth(method = "auto", formula = y ~ x, se = TRUE, n = 80, fullrange = FALSE, level = 0.95)
```

```
x, y | ..se.,..x.,..y.,..ymin.,..ymax..
```

```
ggplot() + stat_function(aes(x = 3:3), fun = dnorm, n = 101, args = list(sd = 0.5))      Usage général
```

```
x | ..y..
```

```
f + stat_identity()
```

```
ggplot() + stat_qq(aes(sample = 1:100), distribution = qt, dparams = list(df = 5))
```

```
sample, x, y | ..x.,..y..
```

```
f + stat_sum()
```

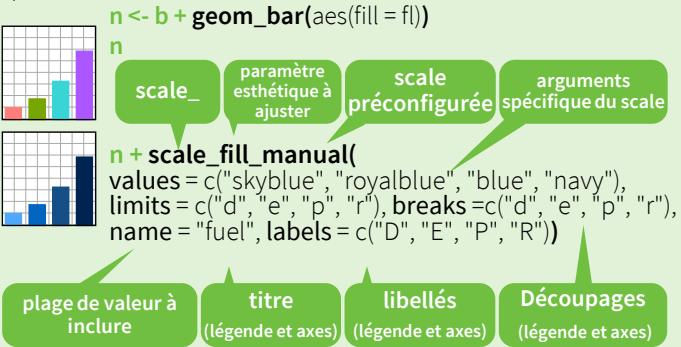
```
x, y, size | ..size..
```

```
f + stat_summary(fun.data = "mean_cl_boot")
```

```
f + stat_unique()
```

Echelles (Scales)

Les « Scales » déterminent la façon dont un graphique affiche les valeurs de données en accord avec les paramètres esthétiques. Pour modifier le rendu, ajoutez une échelle personnalisée.



scales couramment utilisées

A utiliser avec tous paramètres esthétiques : alpha, color, fill, linetype, shape, size

scale_*_continuous() échelle continue

scale_*_discrete() échelle discrète

scale_*_identity() échelle identité

scale_*_manual(values = c()) permet de choisir manuellement les valeurs de l'échelle

scales associées à X et Y
A utiliser avec le paramètre esthétique x ou y (exemple ici avec x)

scale_x_date(labels = date_format("%m/%d"), breaks = date_breaks("2 weeks")) considère les valeurs de x en tant que date. cf ?strptime

scale_x_datetime() considère les valeurs de x en tant que datetime. Utilise les mêmes arguments que scale_x_date().

scale_x_log10() échelle logarithmique pour l'axe x

scale_x_reverse() inverse l'axe des x

scale_x_sqrt() échelle « racine carrée » pour l'axe x

scales de couleur et remplissage

Discreté Continue

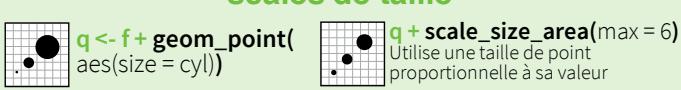


scales de forme

correspondance valeur et forme



scales de taille



Système de coordonnées

r <- b + geom_bar()

r + coord_cartesian(xlim = c(0, 5))
xlim, ylim
Coordonnées cartésiennes par défaut

r + coord_fixed(ratio = 1/2)

ratio, xlim, ylim
Coordonnées cartésiennes à proportion fixe entre x et y

r + coord_flip()

xlim, ylim
Coordonnées cartésiennes inversées

r + coord_polar(theta = "x", direction = 1)

theta, start, direction

Coordonnées polaires

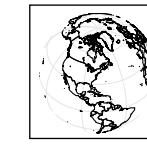
r + coord_trans(ytrans = "sqrt")

xtrans, ytrans, limx, limy
Coordonnées cartésiennes transformées.
Utilise des fonctions de fenêtrage dans xtrans et ytrans.

z + coord_map(projection = "ortho",

projection, orientation, xlim, ylim

Cartographie du package mapproj (mercator (default), aequalarea, lagrange, etc.)



Vignettage

Permet de diviser un graphique en sous graphiques en fonction d'une ou plusieurs variables discrètes.

t <- ggplot(mpg, aes(cty, hwy)) + geom_point()



Utiliser le paramètre scales pour autoriser des limites d'échelles différentes entre graphiques

t + facet_grid(y ~ x, scales = "free")

ajuste les limites des axes x et y de chaque graph

- "free_x" ajuste les limites de l'axe x
- "free_y" ajuste les limites de l'axe y

Utiliser labeller pour ajuster les libellés

t + facet_grid(. ~ fl, labeller = label_both)

fl: c fl: d fl: e fl: p fl: r

t + facet_grid(. ~ fl, labeller = label_bquote(alpha ^ .(x)))

fl^c fl^d fl^e fl^p fl^r

t + facet_grid(. ~ fl, labeller = label_parsed)

c d e p r

Libellés

t + ggtitle("Nouveau titre du graphique")

Ajoute un titre principal au graphique

t + xlab("titre des abscisses")

Change le libellé des abscisses

t + ylab("titre des ordonnées")

Change le libellé des ordonnées

t + labs(title = "Titre", x = "abscisse", y = "ordonnée")

Tout ce qui précède en une seule fonction

Utiliser les fonctions "scale" pour mettre à jour les libellés des légendes

Légende

t + theme(legend.position = "bottom")

Déplace la légende : "bottom", "top", "left", ou "right"

t + guides(color = "none")

Définit le format de la légende pour chaque propriété esthétique : colorbar, legend, ou none (aucune légende)

t + scale_fill_discrete(name = "Titre", labels = c("A", "B", "C"))

Précise le titre et le libellé de la légende avec une fonction scale.

Zoom

Sans coupure (à privilégier)

t + coord_cartesian(xlim = c(0, 100), ylim = c(10, 20))

Avec coupure (supprime les points invisibles)

• **t + xlim(0, 100) + ylim(10, 20)**

• **t + scale_x_continuous(limits = c(0, 100)) + scale_y_continuous(limits = c(0, 100))**