SD-lab5

ȘD - Scop Laboratorul 5

Scopul laboratarului 5 de Știința Datelor este:

- dezvoltarea capacității de a produce un graf

```
library("ggplot2")
library("ggplot2movies")
library("maps")
library("dplyr")
library("tidyr")
library("lubridate")
library("maps")
library("mapdata")
library("sp")
library("RColorBrewer")
set.seed(20)
```

TLDR; Treceți la Exerciții, dacă nu există cheful de citit text lung. În mare se discută despre grafice. Probabil să revii când faci licența, dacă nu ai auzit de gnuplot și awk (Spoiler Alert: Nici în labul acesta nu se face).

Analiza Datelor

Vom folosi pentru analiza setul de date europene legat de poluarea aerului în România [http://cdr.eionet.europa.eu/ro/eu/aqd/e1a] [https://www.eea.europa.eu/data-and-maps/data/aqereporting-8]. Am decis să folosim aceste date pentru că [https://www.youtube.com/watch?v=Q69oWhgFp04] (Boomer joke). :sadface pentru cei ce se așteptau la o manea, măcar intro-ul melodiei nu mai sună la fel de bine în ziua de azi. Revenind la datele noastre, avem date pe toți ani din intervalul 2013-2019. De interes pentru noi o să fie coloanele "StartDate" (reprezintă momentul de început al intervalului peste care a fost făcută media valoriilor), "Value" (Valoarea pentru poluantul respectiv în unitatea de măsură reprezentativă pentru acesta), "ID" (Id-ul stației care a făcut măsurătoarea) și "PolluantCode" (Codul poluantului pe care îl puteți găsi la următorul link [http://dd.eionet.europa.eu/vocabulary/aq/pollutant]). Pentru început citim datele din 2013 și 2019.

```
RoPollutionFilePath <- file.path("data", "poluare2019.csv")
RoPollutionData2019 <- read.csv(RoPollutionFilePath)
RoPollutionData2019$X <- NULL
colnames(RoPollutionData2019)[1] <- "StartDate"
colnames(RoPollutionData2019)[2] <- "EndDate"
colnames(RoPollutionData2019)[3] <- "Value"
colnames(RoPollutionData2019)[4] <- "Validity"
colnames(RoPollutionData2019)[5] <- "Verfication"
colnames(RoPollutionData2019)[6] <- "ID"
colnames(RoPollutionData2019)[7] <- "PolluantCode"
RoPollutionData2019$StartDate <- ymd_hms(RoPollutionData2019$StartDate)
RoPollutionData2019$ID <- factor(RoPollutionData2019$ID)
```

```
RoPollutionData2019$PolluantCode <- factor(RoPollutionData2019$PolluantCode)
RoPollutionData2019$Value <- as.numeric(RoPollutionData2019$Value)
head(RoPollutionData2019)
```

```
##             StartDate             EndDate Value Validity Verfication
## 1 2018-12-31 22:00:00 2018-12-31 23:00:00  0.00        1          -1
## 2 2018-12-31 23:00:00 2019-01-01 00:00:00  7.29        1           1
## 3 2019-01-01 00:00:00 2019-01-01 01:00:00  6.90        1           1
## 4 2019-01-01 01:00:00 2019-01-01 02:00:00  7.02        1           1
## 5 2019-01-01 02:00:00 2019-01-01 03:00:00  7.08        1           1
## 6 2019-01-01 03:00:00 2019-01-01 04:00:00  6.93        1           1
##                   ID PolluantCode
## 1 RO0066A_00001_100            1
## 2 RO0066A_00001_100            1
## 3 RO0066A_00001_100            1
## 4 RO0066A_00001_100            1
## 5 RO0066A_00001_100            1
## 6 RO0066A_00001_100            1
```

```
RoPollutionFilePath <- file.path("data", "poluare2013.csv")
RoPollutionData2013 <- read.csv(RoPollutionFilePath)
RoPollutionData2013$X <- NULL
colnames(RoPollutionData2013)[1] <- "StartDate"
colnames(RoPollutionData2013)[2] <- "EndDate"
colnames(RoPollutionData2013)[3] <- "Value"
colnames(RoPollutionData2013)[4] <- "Validity"
colnames(RoPollutionData2013)[5] <- "Verfication"
colnames(RoPollutionData2013)[6] <- "ID"
colnames(RoPollutionData2013)[7] <- "PolluantCode"
RoPollutionData2013$StartDate <- ymd_hms(RoPollutionData2013$StartDate)
RoPollutionData2013$ID <- factor(RoPollutionData2013$ID)
RoPollutionData2013$PolluantCode <- factor(RoPollutionData2013$PolluantCode)
RoPollutionData2013$Value <- as.numeric(RoPollutionData2013$Value)
head(RoPollutionData2013)
```

```
##             StartDate             EndDate Value Validity Verfication
## 1 2012-12-31 22:00:00 2012-12-31 23:00:00  9.29        1           1
## 2 2012-12-31 23:00:00 2013-01-01 00:00:00  9.20        1           1
## 3 2013-01-01 00:00:00 2013-01-01 01:00:00  9.68        1           1
## 4 2013-01-01 01:00:00 2013-01-01 02:00:00  9.42        1           1
## 5 2013-01-01 02:00:00 2013-01-01 03:00:00  9.77        1           1
## 6 2013-01-01 03:00:00 2013-01-01 04:00:00  9.76        1           1
##                                         ID PolluantCode
## 1 RO.ANPM.AQ-OBP-RO0008R_00001_100_100_2013           1
## 2 RO.ANPM.AQ-OBP-RO0008R_00001_100_100_2013           1
## 3 RO.ANPM.AQ-OBP-RO0008R_00001_100_100_2013           1
## 4 RO.ANPM.AQ-OBP-RO0008R_00001_100_100_2013           1
## 5 RO.ANPM.AQ-OBP-RO0008R_00001_100_100_2013           1
## 6 RO.ANPM.AQ-OBP-RO0008R_00001_100_100_2013           1
```

Grafice de analiză

Scopul acestui colos textual este de a vă oferi niște idei despre formarea unui grafic de analiză. Graficele de analiză sunt cele pe care le prezentați după analiză datelor pentru a arăta rezultatul muncii voastre. În

cadrul licenței li se mai spun și “chestiile alea pe care se uită membrii comisiei ca să zică că fac ceva”. Unele dintre ele mai apar în prezentarea pe care o ții, #copypaste.

Principiul 1 : Comparație/Ipoteza

Primul principiul maschează expresia “o imagine 1000 de cuvinte”. El vrea să spună că ar trebui să se înțeleagă din grafic ipoteza tezei voastre (“Eu vă prezint proiectul X care este mai bun ca Y sau face mai bine Z din punctul de vedere Y”). În general ipotezele sunt legate de o comparație. Compari ipoteză propusă de tine cu o ipoteză existentă. Cele mai evidente greșeli sunt cele în care se “toarnă” date care reprezintă o linie care se “ridică”. Exemple din perle licență:

```
library("png")
perlaFilePath <- file.path("data", "perla1.png")
img <- readPNG(perlaFilePath)
par(mar = c(0, 0, 0, 0), xpd = NA, mgp = c(0, 0, 0), oma = c(0,
    0, 0, 0), ann = F)
plot.new()
plot.window(0:1, 0:1)
usr <- par("usr")
rasterImage(img, usr[1], usr[3], usr[2], usr[4])
```

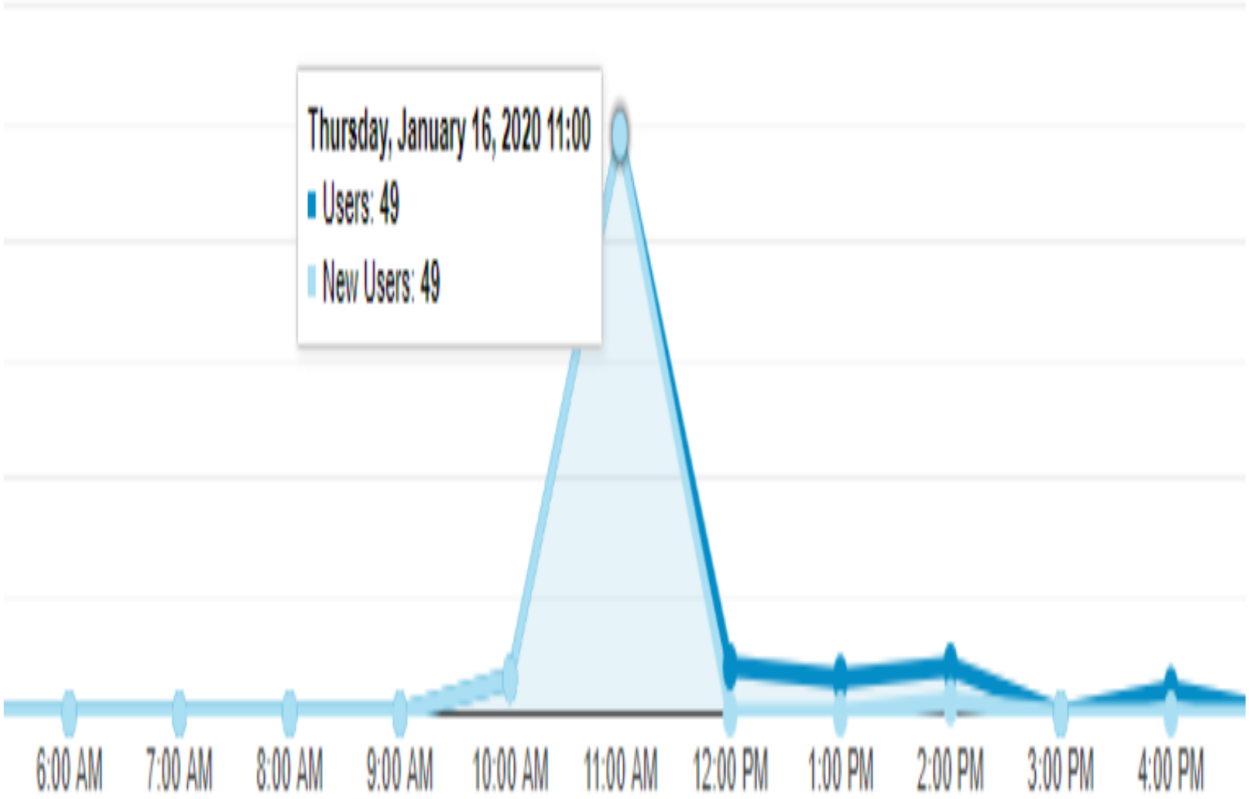

Acest exemplu e “bun” deoarece linia “coboară” după ce se “ridică”, aproape că vrea să transmită un mesaj. Acesta poate fi un grafic bun pentru explorare, dar în cazul analizei nu oferă nimic. E cumva specială data și ora de 16 ianurie 2020 11:00 (ultimul test de curs la pr)? Are vreo importanță diferența dintre utilizatori și utilizatori noi. Pe datele noastre echivalentul ar fi să afișăm distribuția poluantului dioxid de sulf în anul 2019.

```
RoData2019_SO_2 <- RoPollutionData2019 %>% filter(PolluantCode ==
    1)
boxplot(RoData2019_SO_2$Value)
```

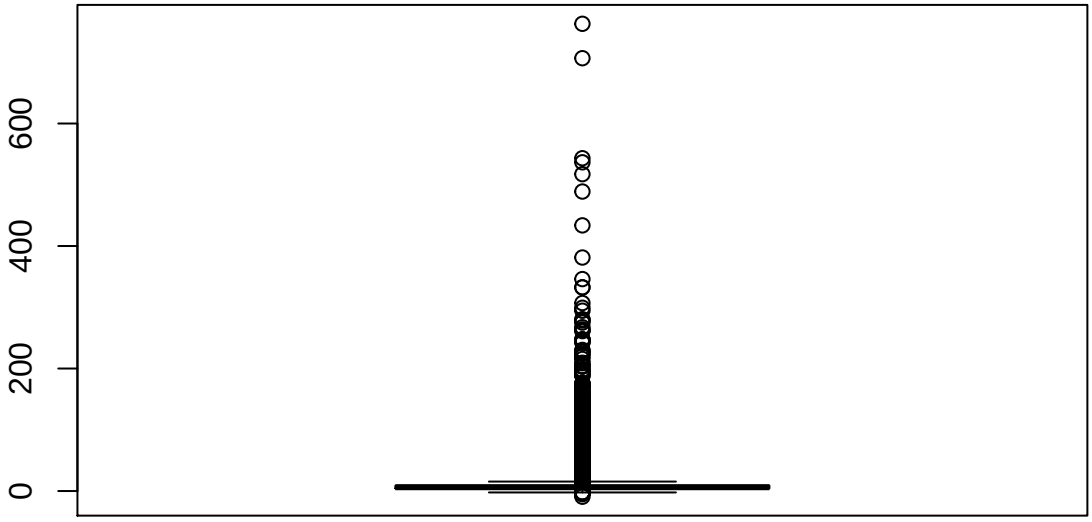

Putem spune că avem un grafic cu un mesaj "evident" și "puternic", dar fără să ne ofere vreun detaliu de analiză asupra datelor. Nu aveam cum să transmitem un mesaj atât timp cât nu avem o ipoteză. La următorul link [https://ec.europa.eu/environment/air/quality/standards.htm] găsim limitele recomandate de unuiunea europeană. Putem alege ipoteza "România respectă limitele recomandate pentru poluantul dioxid de sulf". Vom compara în graficul nostru cu valaorea limitei dioxidului de sulf. O altă problemă este reprezentată de faptul că punctele sunt concentrate și nu sunt vizibile. Pentru a rezolva această problemă se scalează. O metodă este de a trece în bază logaritmică.

```
boxplot(log(RoData2019_SO_2$Value))
```

```
## Warning in log(RoData2019_SO_2$Value): NaNs produced
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 1 is not drawn
```

```
abline(h = log(350))
```

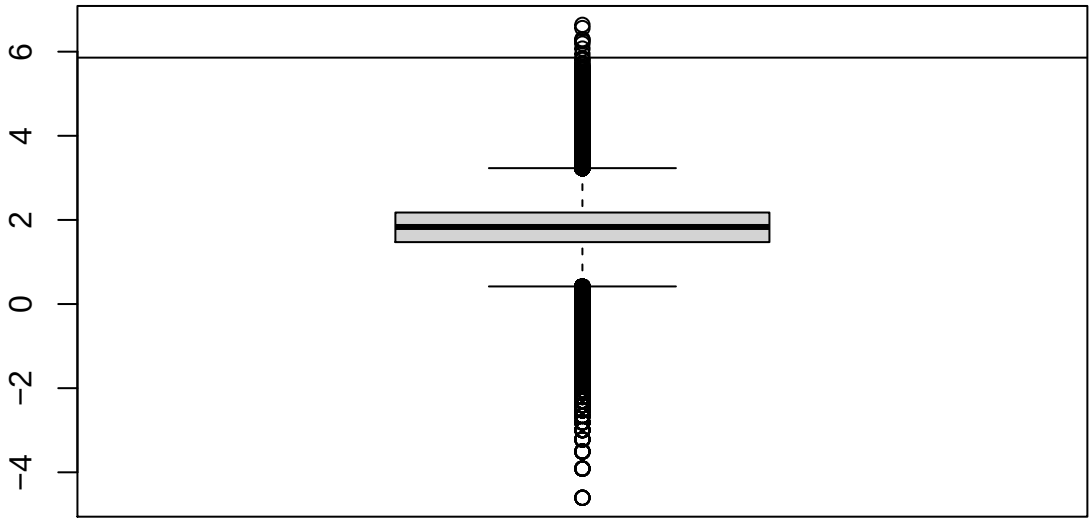

Avem valori ce depășesc limita, dar standardul spune că nu trebuie să avem mai mult de 24.

```
sum(RoData2019_SO_2$Value > 350)
```

```
## [1] 8
```

Noi avem doar 8, deci respectăm recomandările uniunii europene. Totuși această ipoteză e "prea simplă" pentru noi. Se știe că există diferențe între valorile poluanților între anotimpuri. Vom testa această ipoteză pe două anotimpuri: vara și iarna.

```
RoData2019_SO_2_vara <- RoData2019_SO_2 %>% filter(month(StartDate) >
    5 & month(StartDate) < 9)
RoData2019_SO_2_iarna <- RoData2019_SO_2 %>% filter(month(StartDate) >
    11 | month(StartDate) < 3)
boxplot(log(RoData2019_SO_2_vara$Value), log(RoData2019_SO_2_iarna$Value),
    names = c("vara", "iarna"))
```

```
## Warning in log(RoData2019_SO_2_vara$Value): NaNs produced
```

```
## Warning in log(RoData2019_SO_2_iarna$Value): NaNs produced
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 1 is not drawn
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 2 is not drawn
```

```
abline(h = log(350))
```

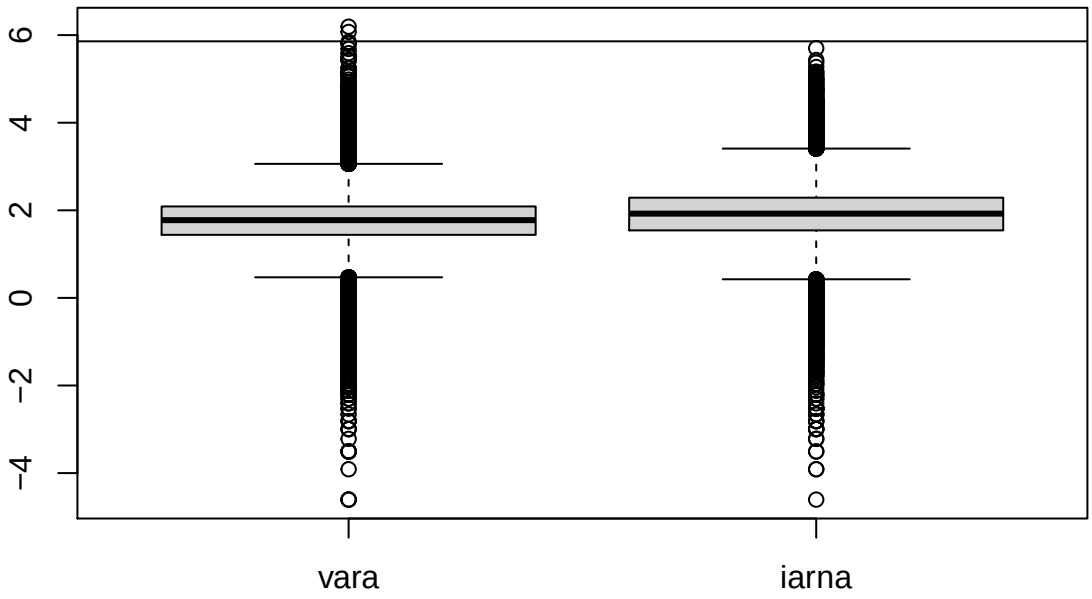

Acum prin această comparație oferim mai multe informații despre datele noastre. Se transmite faptul că valoriile iarna sunt mai mari decât vara (sunt diferențe în bază logaritmică). Limita nu a fost depășită iarna, dar a fost depășită vara. Ce vrerm să transmitem prin acest grafic este că un grafic care are multe comparații în el are o poveste mai lungă și se poate ajunge la cele "1000 de cuvinte". Mai departe trecem la al doilea principiu.

Principiul 2: Cauzalitate, Mecanicism, Explicație, Strucutră

Al doilea principiu se traduce prin "demonstrează ipoteza ta prin grafic". Pentru fiecare în parte: - Cauzalitate - Cauzalitatea este când împarți "mulțimea" ta în "grupuri" pentru care ai folosit "tratamente" diferite. Un exemplu simplu din știința calculatoarelor este cel de a introduce un protocol nou sau un algoritm nou pentru o problemă pentru care mai există soluții. Principiul 2 spune în acest caz să rulezi toți algoritmi pe același set

de date și să afișezi rezultate în același grafic în funcție de o caracteristică pe care o consideri de importanță. Cum marele "ideal" al unui dascăl este să râdă de perlele studenților mai aducem una în discuția publicului:

```
perlaFilePath <- file.path("data", "perla2.png")
img <- readPNG(perlaFilePath)
par(mar = c(0, 0, 0, 0), xpd = NA, mgp = c(0, 0, 0), oma = c(0,
    0, 0, 0), ann = F)
plot.new()
plot.window(0:1, 0:1)
usr <- par("usr")
rasterImage(img, usr[1], usr[3], usr[2], usr[4])
```

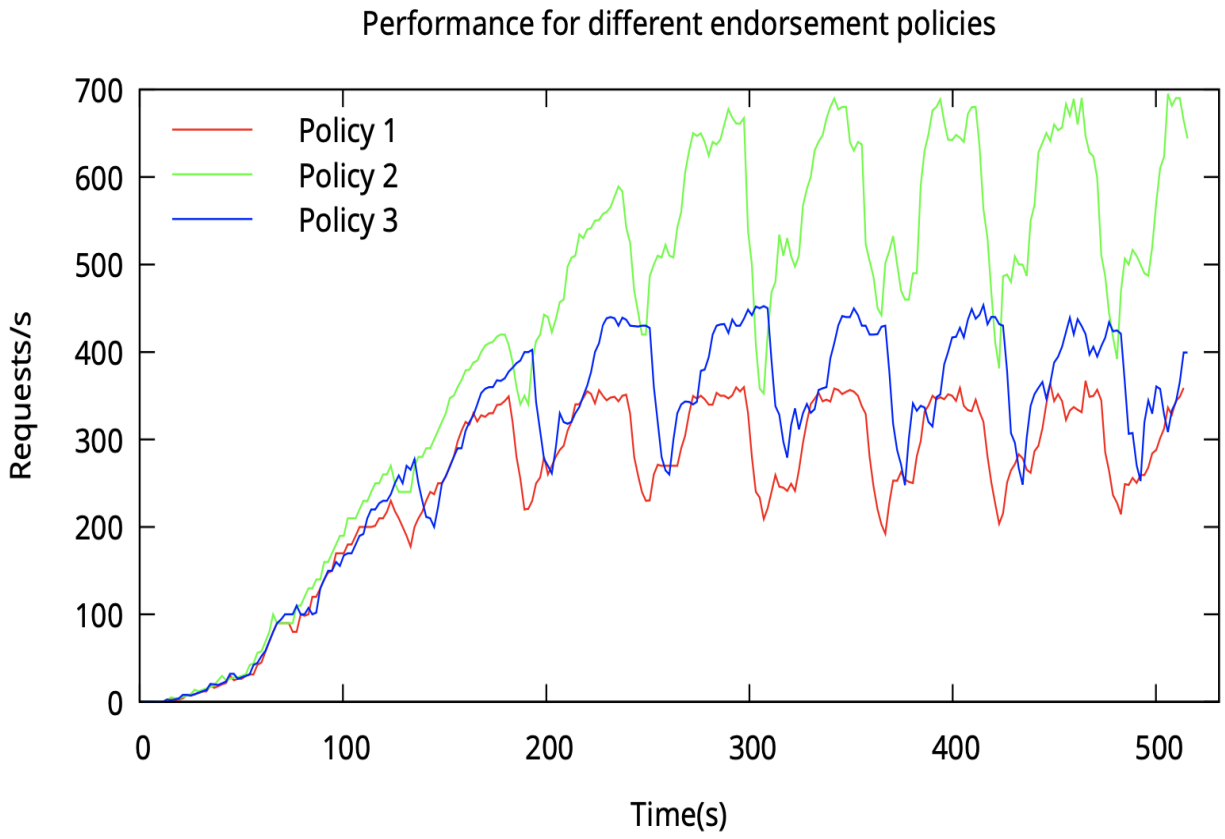

La o primă vedere totul pare înregulă, mai puțin culoriile (:sadcolorblind, #protv). Avem 3 politici distincte care se comportă diferit. Problema este că nu știm care sunt acest politici, cu ce diferă. Ce reprezintă acel "1", "2", "3" ? Sunt niște soluții cunoscute deja ? Sunt toate 3 niște propuneri ? Dacă sunt propuneri cu ce diferă ? Dacă sunt poropuneri ar trebui să avem și o altă soluție cunoscută în domeniu.

Pentru datele folosite în laborator ar trebui să găsim un an în care a fost data o lege pentru reducerea poluării și să vedem dacă aceasta a avut efect în 2 ani consecutii cel dinaintea implementări și primul an al implementări, posibil și al doilea. Din păcate autor e leneș așa că vom compara 2013 cu 2019.

```
RoData2013_SO_2 <- RoPollutionData2013 %>% filter(PolluantCode ==
    1)
boxplot(log(RoData2013_SO_2$Value), log(RoData2019_SO_2$Value),
    names = c("2013", "2019"))
```

```
## Warning in log(RoData2013_SO_2$Value): NaNs produced
```

```
## Warning in log(RoData2019_SO_2$Value): NaNs produced
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 1 is not drawn
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 2 is not drawn
```

```
abline(h = log(350))
```

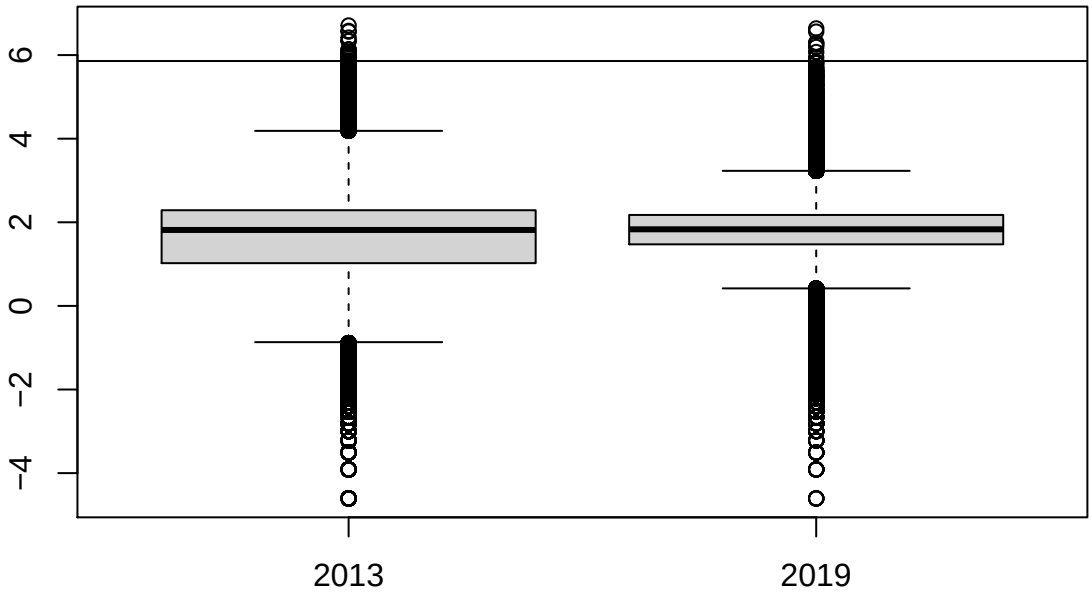

Uitându-ne la grafic putem spune "Dacă nu am avut o problemă ce să rezolvăm". Se paote spune de dragul discuției că au mai scăzut valoriile și sunt mai concentrate, dar să fim serioși dacii frumoși și liberi nu au fost ei mari crescători de bovine. Opera "Moara cu Noroc" are un porcar, nu un "cowboy". Totuși haideți să încercăm poluantul $PM_{2.5}$, că acolo cam toată eruopa a scăzut.

```
RoData2013_PM_2_5 <- RoPollutionData2013 %>% filter(PolluantCode ==
    "6001")
RoData2019_PM_2_5 <- RoPollutionData2019 %>% filter(PolluantCode ==
    "6001")
boxplot(RoData2013_PM_2_5$Value, RoData2019_PM_2_5$Value, names = c("2013",
    "2019"))
abline(h = 25)
```

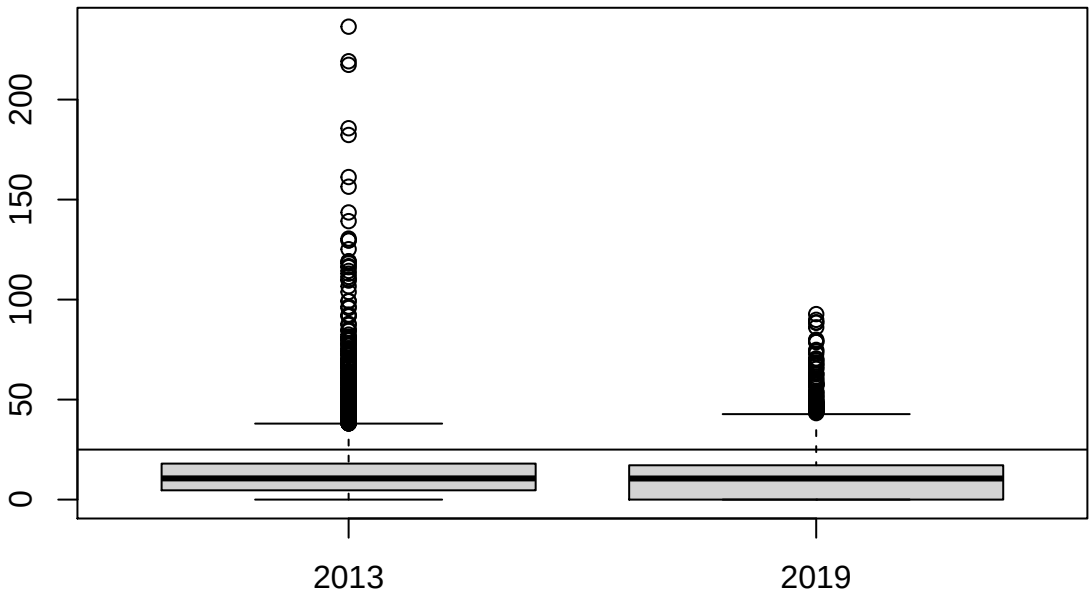

O diferență mai "vizibilă". Pe care putem să o afișă și pe parcursul anului. Se pare că politica României și a Uniunii Europene de a elimina senzorii care ofereau valori "răutăcioase" este un adevărat succes.

```
plot(RoData2013_PM_2_5$StartDate, RoData2013_PM_2_5$Value, type = "n",
    xlab = "Timp", ylab = "Valoare poluant PM_2_5")
points(RoData2013_PM_2_5$StartDate, RoData2013_PM_2_5$Value,
    pch = 18, col = 4)
points(RoData2019_PM_2_5$StartDate - years(6), RoData2019_PM_2_5$Value,
    pch = 19, col = 2)
abline(h = 25, col = 3)
```

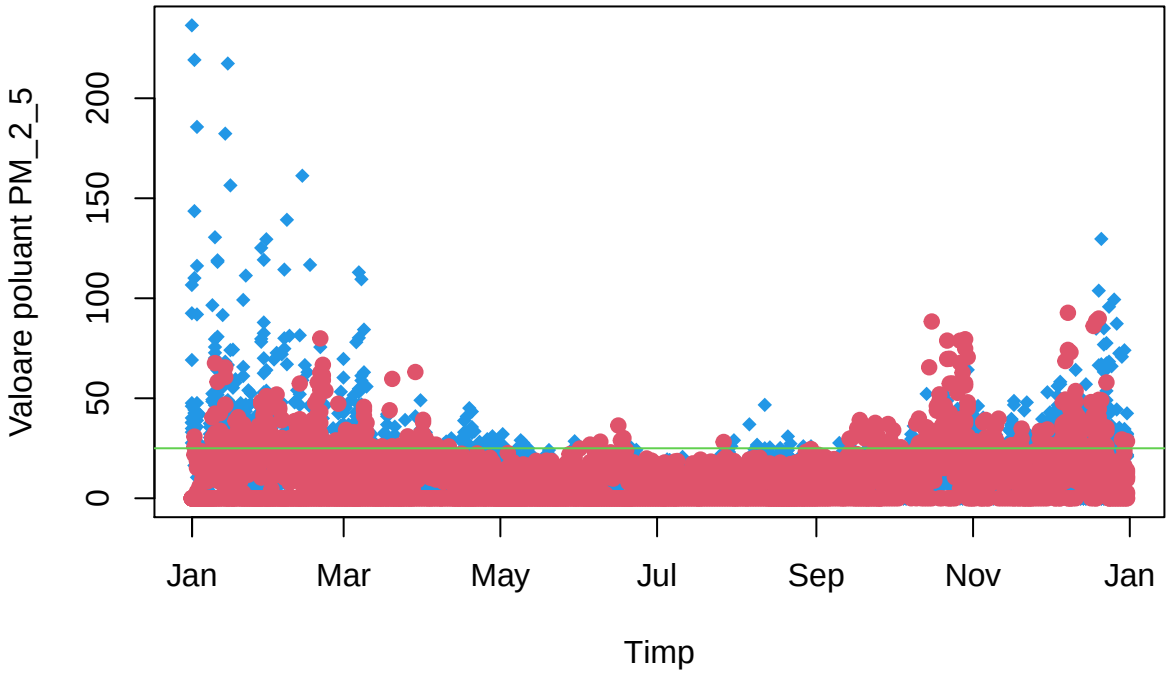

- Mecanicism. Mecanicismul apare atunci când implmentezi o muncă teoretică, care încă nu are o implmentare perfectă sau nu e posibil să aibă. Un exemplu din știința calculatoarelor este reprezentat de protocoalele de rețele precum wi-fi care oefră anumite viteze teoretice maxime. Noi putem veni cu o implementare a standardului și vom arăta în grafic rezultatele noastre (mbps) față de valoriile teoretice

în funcție de numărul de stații. Se mai recomandă afișarea si rezultatele unei simulări (ex: ns3). Astfel, putem vedea cât de mult se aproprie implementarea noastră de formula teoretică. Un alt exemplu din munca renumiților studenți ai acestei facultăți:

```
perlaFilePath <- file.path("data", "perla3.png")
img <- readPNG(perlaFilePath)
par(mar = c(0, 0, 0, 0), xpd = NA, mgp = c(0, 0, 0), oma = c(0,
    0, 0, 0), ann = F)
plot.new()
plot.window(0:1, 0:1)
usr <- par("usr")
rasterImage(img, usr[1], usr[3], usr[2], usr[4])
```

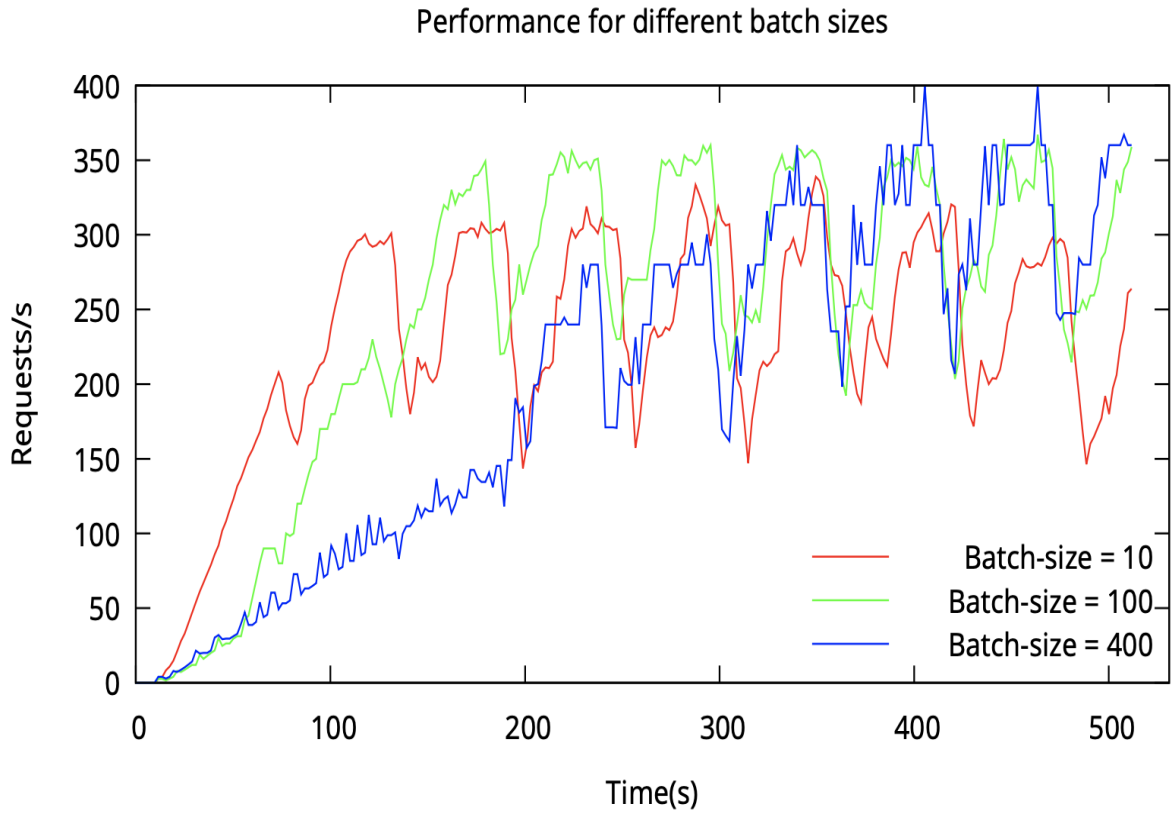

Acest principiul poate fi folosit și când încercăm diferite implementări ce diferă printr-un parametru ca în cazul de mai sus. Însă este necesar să oferim în grafic și rezultatul pe care ni-l dorim sau o presupunere teoretică a unei soluți perfecte. În cazul de față, nu avem cum să ne dăm seama care este soluția mai bună. Ce ne dorim ? mai multe requesturi pe secund pe termen scurt sau lung ? sau ne dorim un număr constant ? Cu toate astea este un grafic bun care transmite faptul că un batch-size mai mare ne oferă un număr mai mare de request pe secundă pe termen lung. De asemenea se pare că avem o plafonare după pentru un size mai mare de 100 pe termen lung.

Revenind la datele noastre, pentru $PM_{2.5}$ ar trebui să calculăm cât poluează mașinile înamtriculate în România și astfel să descoperim județul cu cele mai multe mașini înmatriculate pe Bulgaria (<3 Vâlacea). Sau putem vedea ce județ are cele mai multe permise de conducere per mașină înamtriculată (<3 Suceava, :(Argeș).

- Explicația. Adeseori explicația pentru rezultatele noastre nu este atât de apropiată de date sau știută/controlată dinainte ca în cazurile precedente. Aici va trebui să "săpăm". Revenim cu un grafic

din categoria “Să fie să ocupe loc”:

```
perlaFilePath <- file.path("data", "perla4.png")
img <- readPNG(perlaFilePath)
par(mar = c(0, 0, 0, 0), xpd = NA, mgp = c(0, 0, 0), oma = c(0,
    0, 0, 0), ann = F)
plot.new()
plot.window(0:1, 0:1)
usr <- par("usr")
rasterImage(img, usr[1], usr[3], usr[2], usr[4])
```

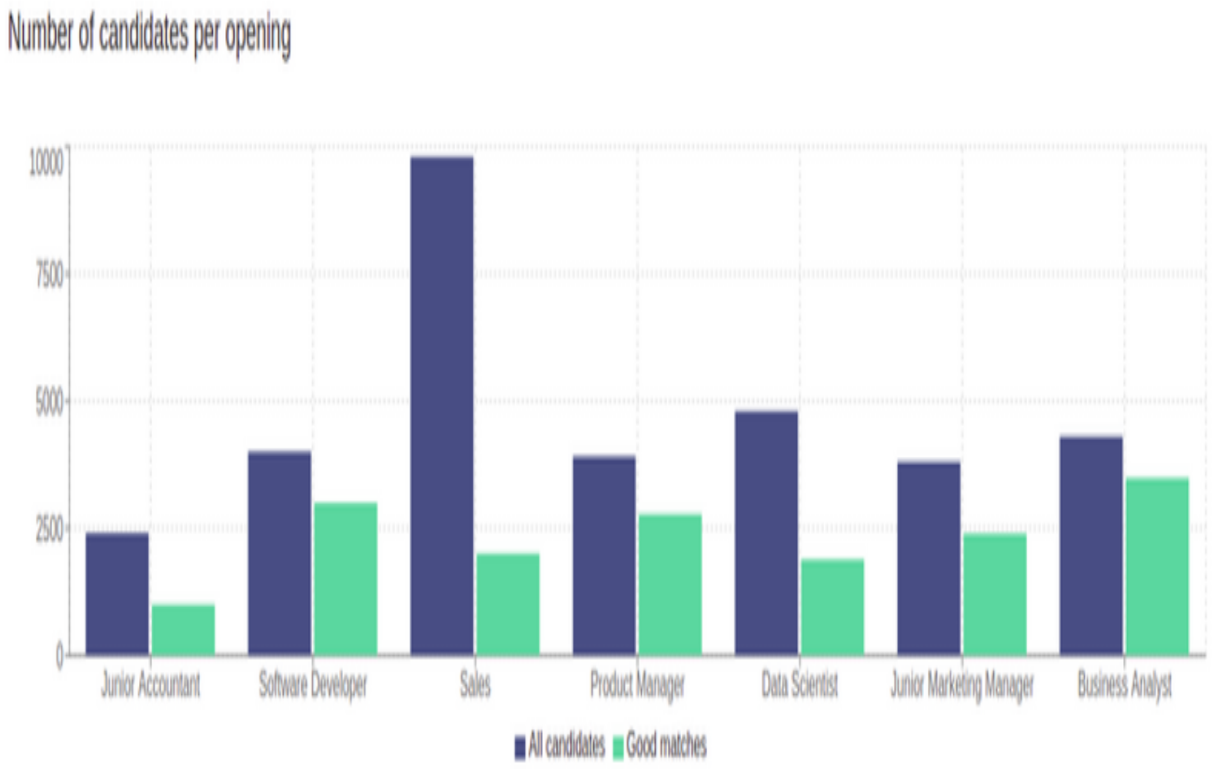

Pare un grafic “frumos”, dar “cam atât”. Acest grafic oferă date fără a oferi explicații, ceea ce ridică mai multe întrebări decât informații. Pentru ce candidează (ce repreîintă opening) ? De ce anumite categorii au un “match” mai bun ? Câte persoane sunt în acele categorii ? Câte persoane din categoria respectivă nu au candidat ? O parte din întrebări ar primi un răspuns dacă am folosi procente. Un grafic care ridică atât de multe întrebări fără a avea o eplicație măcar textuală ocupă spațiu degeaba.

Revenind la datele noastre, putem viziona încă o dată diferențele de dioxid de sulf între anotimpuri.

```
RoData2019_SO_2_vara <- RoData2019_SO_2 %>% filter(month(StartDate) >
    5 & month(StartDate) < 9)
RoData2019_SO_2_iarna <- RoData2019_SO_2 %>% filter(month(StartDate) >
    11 | month(StartDate) < 3)
boxplot(log(RoData2019_SO_2_vara$Value), log(RoData2019_SO_2_iarna$Value),
    names = c("vara", "iarna"))
```

```
## Warning in log(RoData2019_SO_2_vara$Value): NaNs produced
```

```
## Warning in log(RoData2019_SO_2_iarna$Value): NaNs produced
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 1 is not drawn
```

```
## Warning in bplt(at[i], wid = width[i], stats = z$stats[, i], out = z$out[z$group
## == : Outlier (-Inf) in boxplot 2 is not drawn
```

```
abline(h = log(350))
```

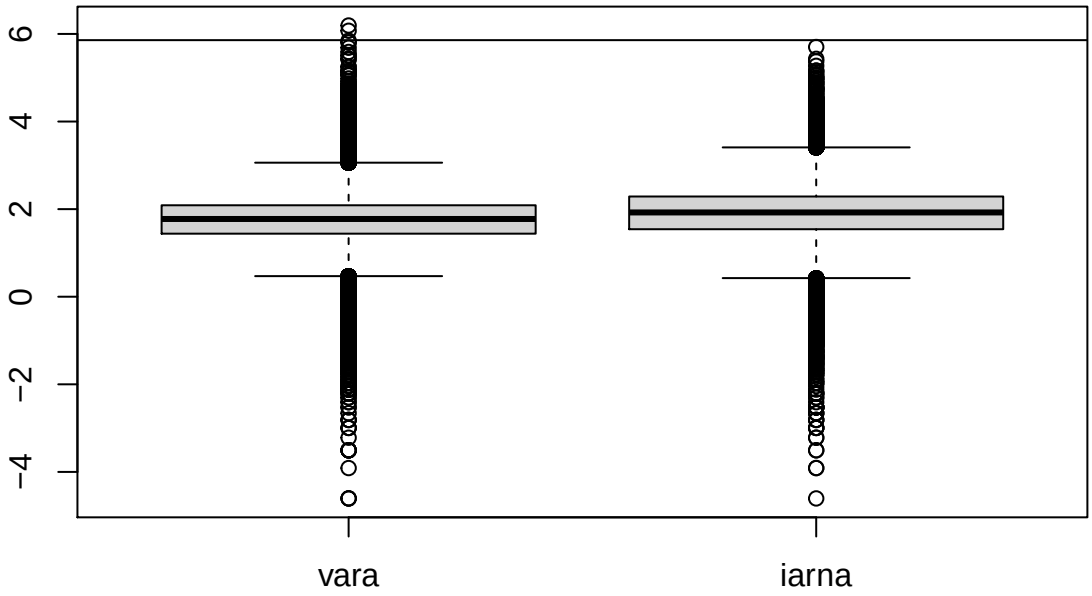

Centralele termice reprezintă unul din poluatori prinicipali de dioxid de carbon. Cum iarna este mai frig centralele termice funcționează la o capacitate mai mare deci poluează mai mult și asta explică diferența dinte cele două anotimpuri. Desigur graficul de mai sus este incomplet, acesta necesită și adăugarea boxplot-rilor pentru temperaturi în perioada respectivă, dar, din păcate, autorul a jucat Dota 2.

- Structura - Conceptul de structură e cel mai detaliat și complex dintre cele prezentate până acum. Pe scurt este "Să ai datele structurate după varibile cu legături dintre ele". Asta înseamnă că ai cunoștințe profunde în domeniul respectiv pentru a putea face legătura între diferite varaibile și tabele. În principiu știi cât de mult influențează o variabilă altă variabilă. Un alt exemplu din plaiurile calculatoriste:

```
perlaFilePath <- file.path("data", "perla5.png")
img <- readPNG(perlaFilePath)
par(mar = c(0, 0, 0, 0), xpd = NA, mgp = c(0, 0, 0), oma = c(0,
    0, 0, 0), ann = F)
plot.new()
plot.window(0:1, 0:1)
usr <- par("usr")
rasterImage(img, usr[1], usr[3], usr[2], usr[4])
```

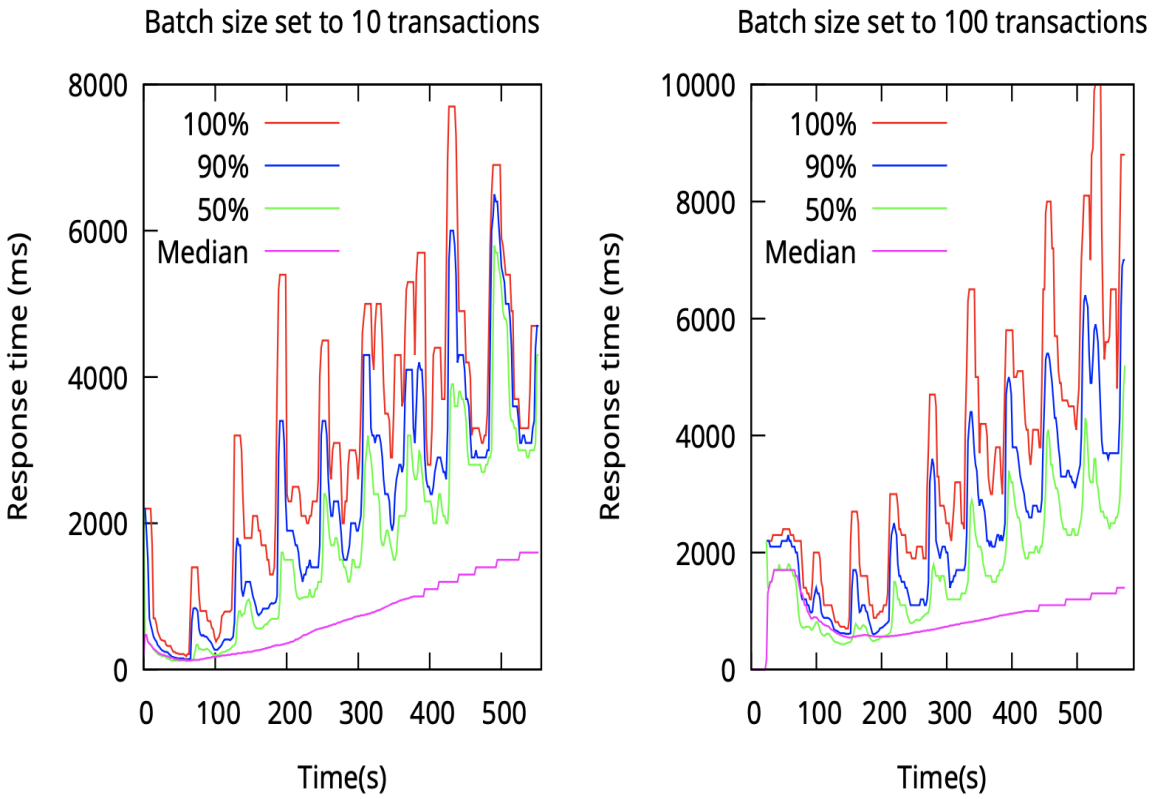

Craatorul acestui grafic cunoaște că batch size-ul influențează timpul de răspuns și structurează separat aceste 2 grafice pentru a vedea influența sa statistică asupra timpului de răspuns. Din păcate nici până în ziua de azi autorul nu știe ce înseamnă linia verde și de ce e diferită de mediană sau cum a răspuns creatorul: "Când l-am făcut știam eu și Dumnezeu. Acum doar Dumnezeu mai știe". Din păcate nu avem un mod sigur de comunicare cu El și nici unul din mebrii comisiei în urma sacrificării nu are speranțe să ajungă prea aproape de El.

Revenind la datele noastre, autorul nu are cunoștințe despre poluanți. Cea mai simplă influență este cea dintre $PM_{2.5}$ și PM_{10} .

După parcurgerea principiului 2 cred că cititorul este destul de aproape de ghicerea celui de al treilea, mai ales prin faptul că este pe linia de sub această propoziție.

Principiul 3: Multitudine de variabile

Al treilea principiu spune "lumea reală este compusă din mai mult de 2 variabile". Ideea este să reprezentăm cât mai multe varaibile într-un singur grafic (deoarece fiecare variabilă aduce informație) fără însă a ridica prea multe întrebări la care acesta să nu răspundă. Într-un mod ciudat acest principiu se "simte", dar se execută într-un mod "deosebit". Urmează un astfel de exemplu:

```
perlaFilePath <- file.path("data", "perla6.png")
img <- readPNG(perlaFilePath)
par(mar = c(0, 0, 0, 0), xpd = NA, mgp = c(0, 0, 0), oma = c(0,
    0, 0, 0), ann = F)
plot.new()
plot.window(0:1, 0:1)
usr <- par("usr")
```

```
rasterImage(img, usr[1], usr[3], usr[2], usr[4])
```

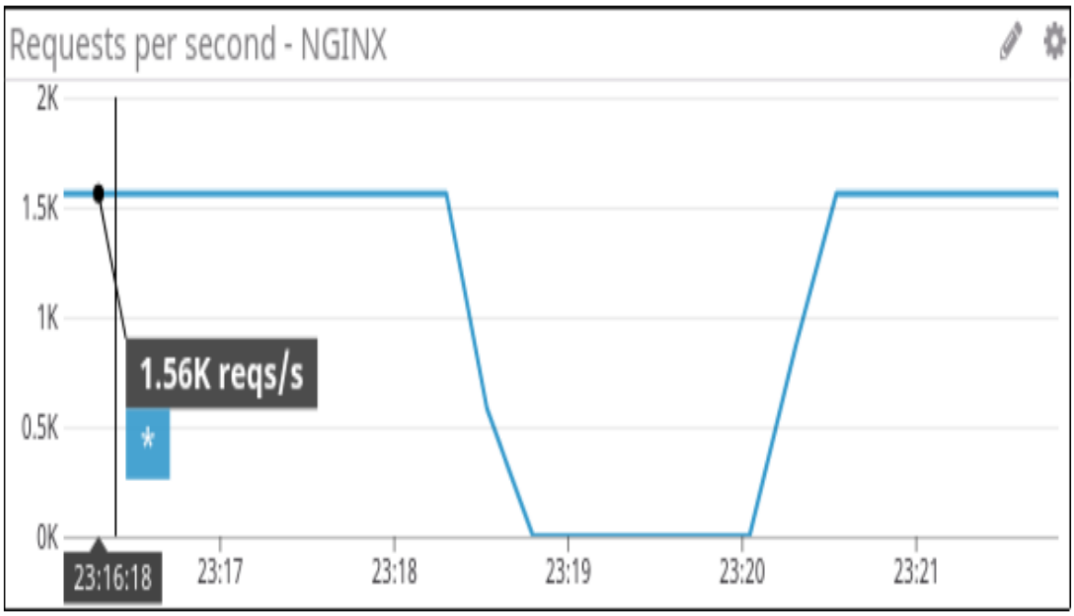

Figura 31: Numărul de cereri pe secundă (primul test)

S-a "simțit" că numărul testului este o varibilă, dar s-a decis să fie făcut cât un graf pentru fiecare test, deoarece toată lumea știe că un album foto este mult mai bun decât o singură poză. Un grafic face cât 1000 de cuvinte, dar 10 grafice fac cât o carte. Ideea este să nu ne fie frică să punem cât mai multe variabile într-un singur grafic, mai ales când este necesar ca în cazul de față.

Revenind la datele noastre, am dori să vedem pe fiecare lună pentru fiecare senzor valoriile poluantului $PM_{2.5}$.

```
library("lattice")
xyplot(data = RoData2019_PM_2_5, Value ~ month(StartDate) | ID)
```

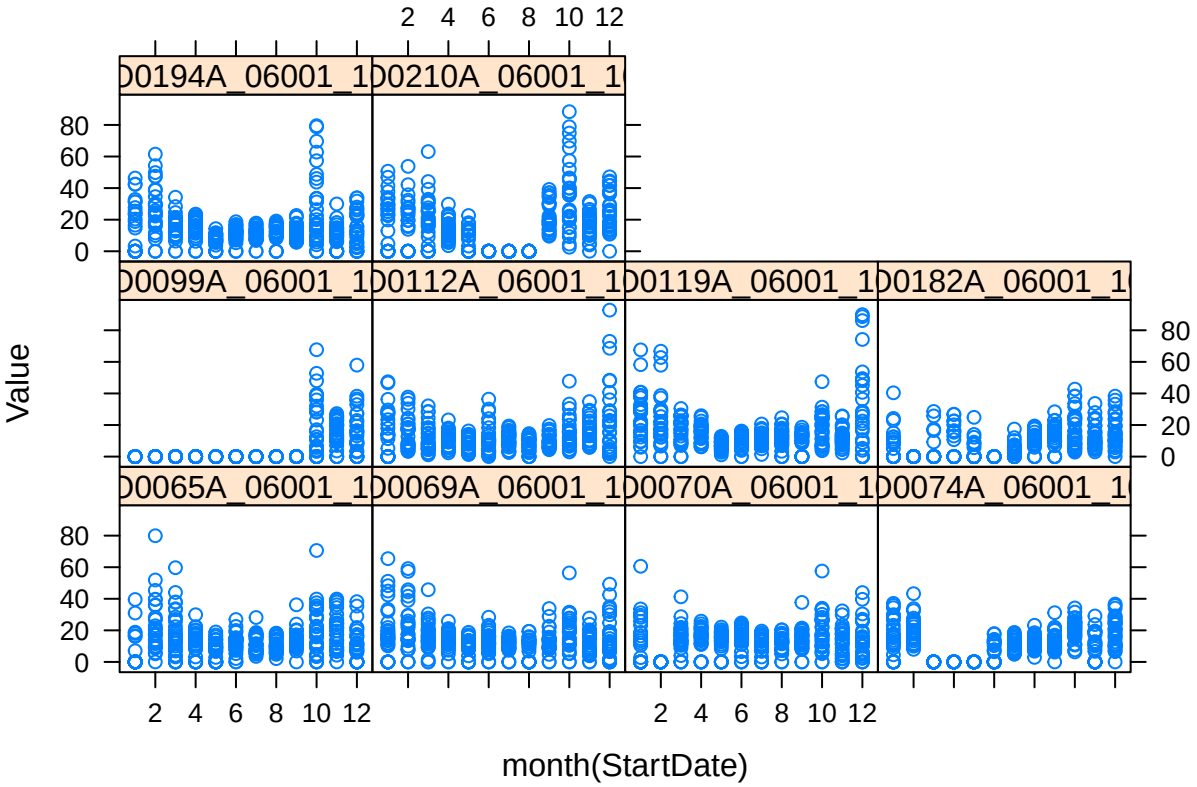

Prin acest grafic complex putem vedea luna și zona în care avem valori ridicate de poluare.

Principiul 4: Dovezi

Al patrulea principiu e ceva de genul "Bă tu mă minți ? Da' ce-am făcut șefu'?". În prinicipal se referă la modul cum ai colectat datele și cum ai făcut experimentul, dacă este un proces valid științific. Aceast lucru se rezolvă textual cel mai des, dar pot exista cazuri în care poți evidenția acest lucru și prin grafice. De exemplu în cazul nostu putem arăta că avem un senzor în fiecare județ.

```
roMetadataFilePath <- file.path("data", "rometadata.csv")
roMetadata <- read.csv(roMetadataFilePath, header = TRUE)

# https://keithnewman.co.uk/r/maps-in-r-using-gadm.html
# https://gadm.org/download_country_v3.html
# https://biogeo.ucdavis.edu/data/gadm3.6/Rsp/gadm36_ROU_1_sp.rds
RoMapFilePath <- file.path("data", "gadm36_ROU_1_sp.rds")
RoMap <- readRDS(RoMapFilePath)
plot(RoMap)
```

```
## Warning in wkt(obj): CRS object has no comment
```

```
points(roMetadata$Longitude, roMetadata$Latitude)
```

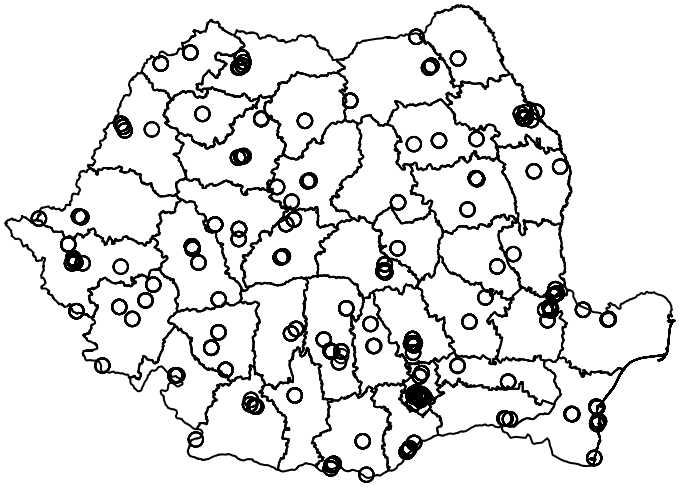

În anumite cazuri din știința calculatoarelor se referă la prezentarea eroriilor de măsurare sau zonei de încredere. În cazul cauzalității trebuie să arătăm există diferențe statistice semnificative între grupuriile noastre de tratament prin teste statistice.

Aici greșelile sunt destul de evidente pe ideea "Am făcut și eu un test șefule", "le-am copiat și eu după net", "așa le-am găsit ce să fac", "erau undeva pe google, am uitat, important e că le am", greșeala pe care am făcut-o și eu mai sus "Nu vezi că e mai sus boxplotul acela" (chiar dacă uneori e evidentă din boxplot diferența, este necesară să facem și testele statistice). Uneori pot exista și răspunsuri complexe precum acest video [https://www.youtube.com/watch?v=CAyWN9ba9J8].

Principiul 5: Descriere și documentare

Al cincilea principiu se referă la titlu, axele și legenda graficului. Este important să avem numele axelor detaliat cu unitățiile de măsură. Titlul trebuie să reprezinte ipoteza pe care vrem să o demonstrăm cu ajutorul graficului. În caz de avem mai multe grupuri de date separate prin culori sau semne diferite este necesar să avem o legendă (nu cu harap-alb).

Principiul 6: Conținutul

Al șaseala principiu pe "scurt": "explică ce se află prin grafic pentru cei ce nu înțeleg din prima , ca a doua oară să îl înțeleagă când îl văd" sau "explică măcar ce ai vrut să faci în grafic". În general se cam scrie ceea ce ție ți se pare evident din grafic. Greșeala aici este să nu scri.

Revenind la datele noastre, ar trebui să explicăm că există o diferență statistică pentru dioxid de sulf între iarna și vară și că se datorează centralelor termice. De asemenea, am putea vorbi despre evoluția României în intervalul de timp 2013-2019.

Conținutul este cel mai important, deaorece poate întipări graficul în memoria cititorului.

P.S.

Exemplele de mai sus nu vor să ia în dărâdere munca creatoriilor lor. Vina este a administrației facultății și coordonatoriilor care nu oferă o pregătire necesară unei lucrări științifice, dar cere una. Acest lucru duce la o calitate scăzută a lucrăriilor de licență, dar de ce să ne pese "studentul trece bănuțul vine la băiatu"'.

Grafice de explorare

Graficiele de explorare sunt pentru înțelegerea datelor de către cel ce vrea să analizeze datele. Acestea sunt utilizate pentru: - înțelegerea unor proprietăți a datelor - găsirea unor structuri a datelor - sugerarea de modele de analiză - descoperirea unor erori de analiză

Caracteristici specificie: - sunt făcute rapid - un număr mare - obiectivul este înțelegerea personală - nu necesită prea multe detalii și respectarea principiilor unor grafice de analiză - nu sunt necesare customizări pentru o înțeleggere mai bună

```
# plot(roMetadata$Longitude, roMetadata$Latitude)
# library('rworldmap') worldMap <- getMap() RoCoord <-
# data.frame(worldMap@polygons[[which(worldMap$NAME=='Romania')]]@Polygons[[1]]@coords)
# lines(RoCoord$X1, RoCoord$X2, col=2)

# library('maps') library('mapdata') RoCoord <-
# map('worldHires','Romania') plot(RoCoord$x, RoCoord$y,
# col=2, type = 'l', lty = 1) points(roMetadata$Longitude,
# roMetadata$Latitude)

# https://keithnewman.co.uk/r/maps-in-r-using-gadm.html
# https://gadm.org/download_country_v3.html
# https://biogeo.ucdavis.edu/data/gadm3.6/Rsp/gadm36_ROU_1_sp.rds
RoMapFilePath <- file.path("data", "gadm36_ROU_1_sp.rds")
RoMap <- readRDS(RoMapFilePath)
# plot(RoMap) points(roMetadata$Longitude,
# roMetadata$Latitude)
# lines(RoMap@polygons[[1]]@Polygons[[1]]@coords, col=2)
```

O singură dimensiune

Pentru o singură dimensiune avem mai multe categorii de grafice de explorare.

Prima metodă care nu este un grafic este denumită sumarizarea celor 5 numere. vom lua în considerare poluarea de $PM_{2.5}$ în România. Conform recomadării Uniunii Europene nu trebuie să avem o medie anuală mai mare de 25.

```
summary(RoPollutionData2019[RoPollutionData2019$PolluantCode ==
    6001, "Value"])
```

```
##    Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
##    0.00    0.00   10.54   11.87   17.15   92.75
```

Se observă că respectăm media, dar avem valori în timpul anului care depășesc media. A doua metodă ce este un grafic de explorare este repzentată de boxplot-uri. Acesta ne arată zona în care se află valoriile noastre.

```
boxplot(RoPollutionData2019[RoPollutionData2019$PolluantCode ==
    6001, "Value"])
abline(h = 25)
```

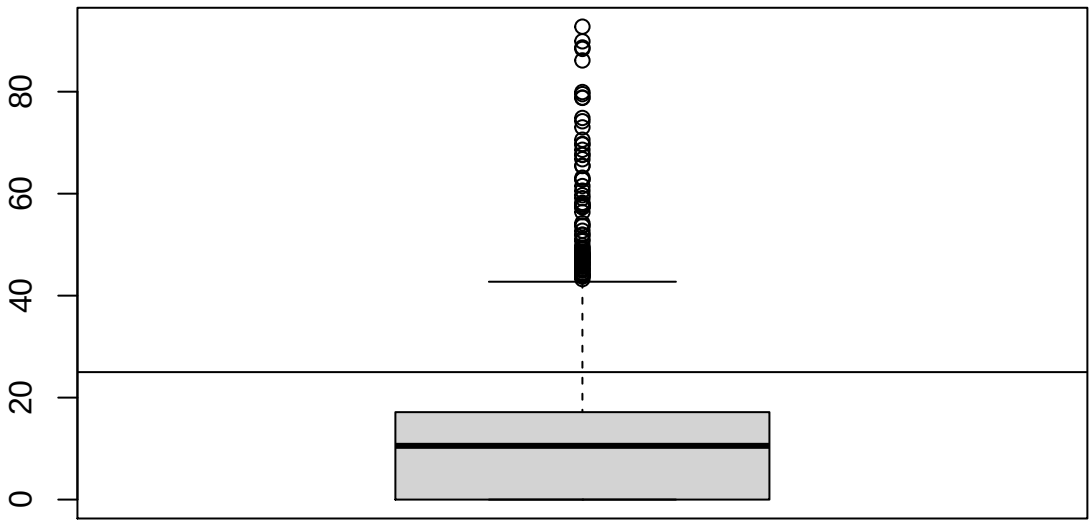

O metodă asemănătoare care ne poate oferi o perspectivă diferită este folosirea histogramelor. Aici putem explora cu ajutorul lățimii de bandă. Este foarte ușor să ajungem în extreme folosind valori prea mari sau prea mici pentru datele noastre.

```
hist(RoPollutionData2019[RoPollutionData2019$PolluantCode ==
    6001, "Value"], breaks = 10)
rug(RoPollutionData2019[RoPollutionData2019$PolluantCode == 6001,
    "Value"])
abline(v = 25, lwd = 2)
```

ram of RoPollutionData2019[RoPollutionData2019$PolluantCode == 60(

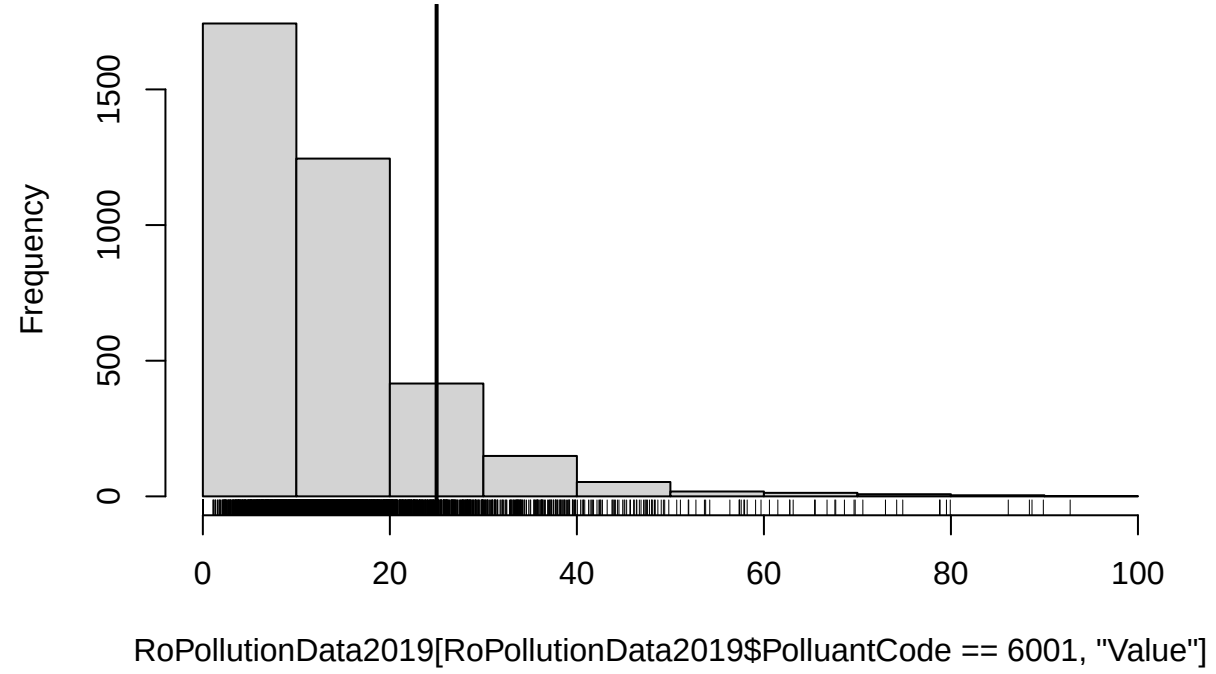


```
hist(RoPollutionData2019[RoPollutionData2019$PolluantCode ==
    6001, "Value"], breaks = 100)
rug(RoPollutionData2019[RoPollutionData2019$PolluantCode == 6001,
    "Value"])
```

```
abline(v = 25, lwd = 2)
```

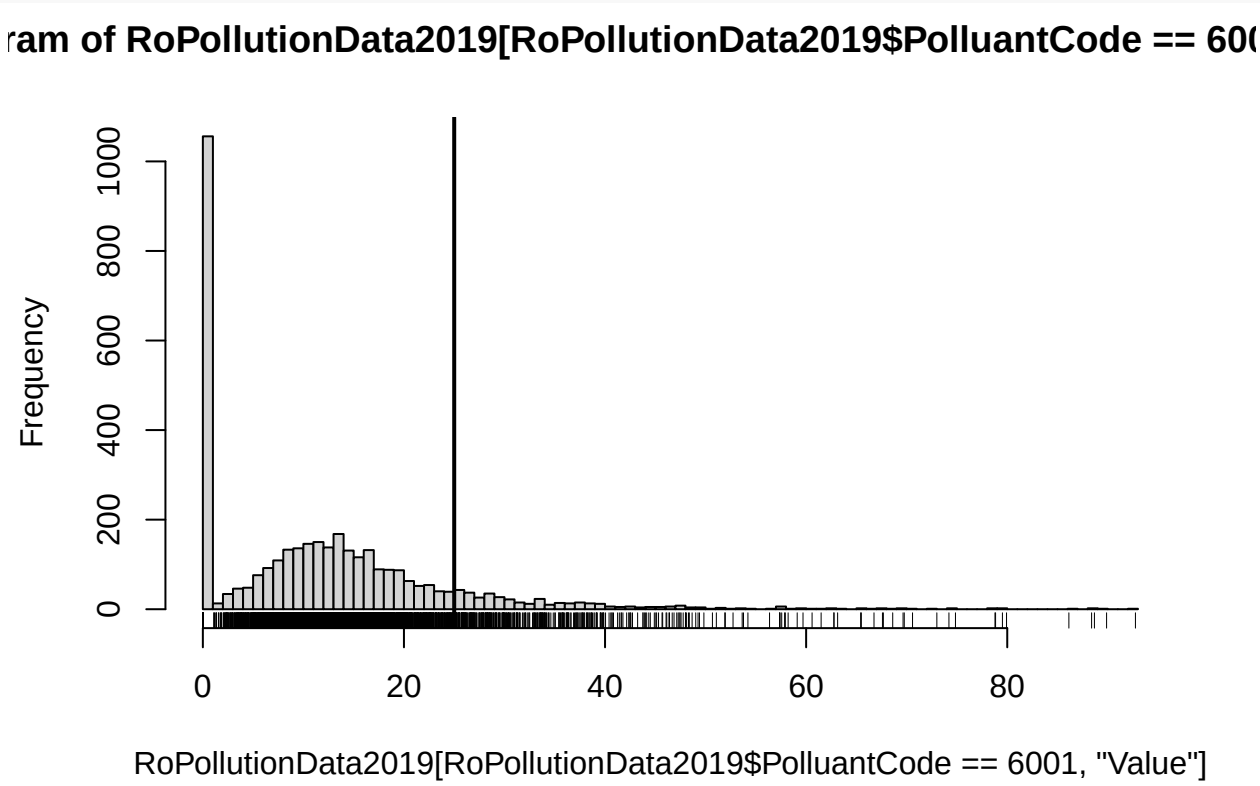

Cele două metode prezentate mai sus sunt specifice datelor continue. Pentru valori discrete putem folosi barplot.

```
barplot(table(RoPollutionData2019$PolluantCode))
```

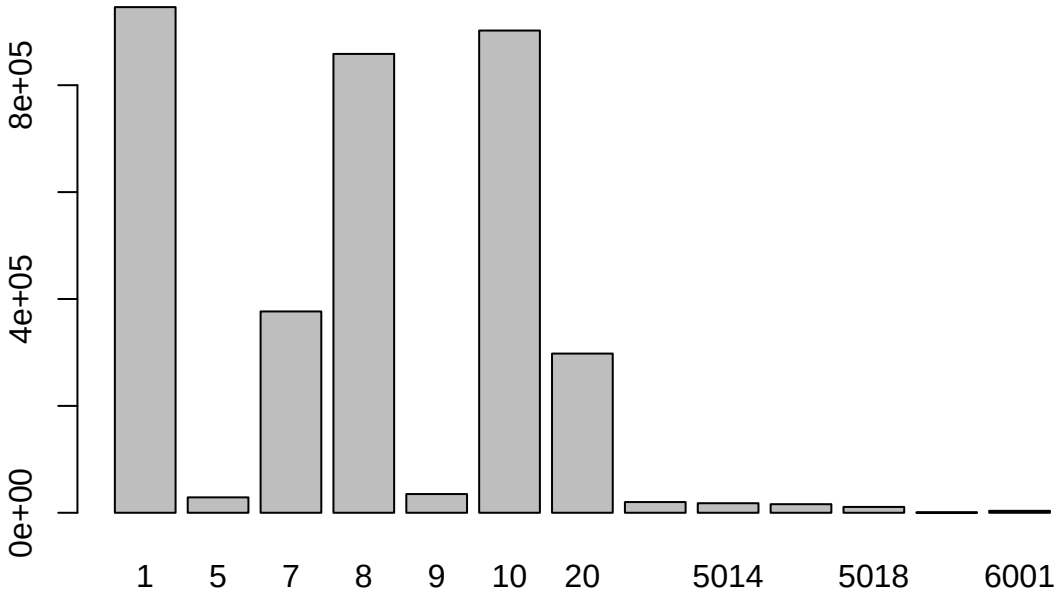

Putem observa pentru ce poluanți avem cele mai multe date. Putem observa numărul de stații per poluant.

```
tmp <- (RoPollutionData2019 %>% group_by(PolluantCode) %>% summarise(unique(ID)) %>%
    select(PolluantCode))$PolluantCode
```

```
## `summarise()` regrouping output by 'PolluantCode' (override with `.groups` argument)
```

```
barplot(table(tmp))
```

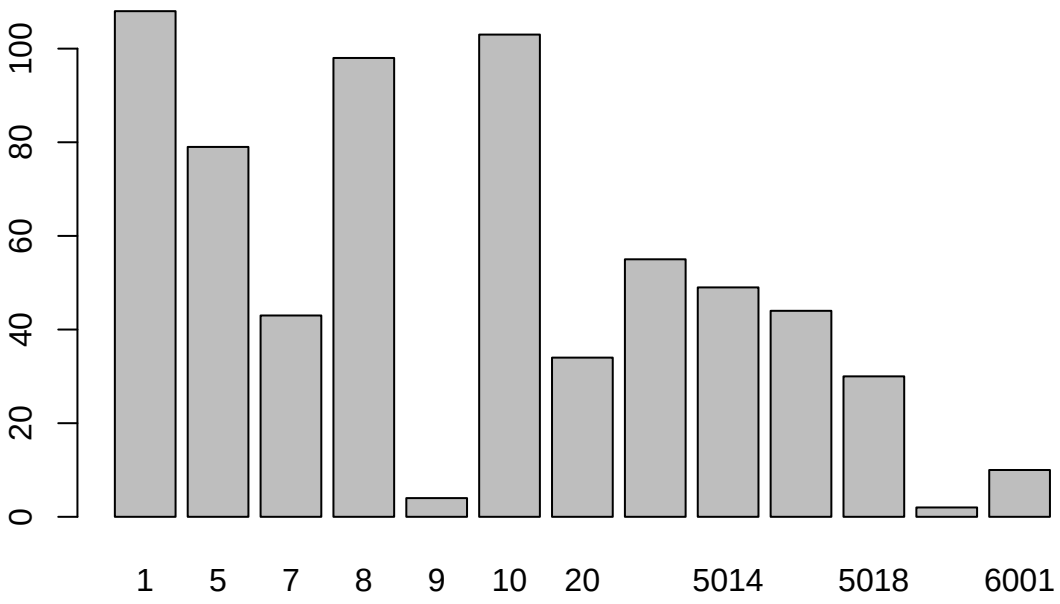

Doua sau mai multe dimensiuni dimensiuni

Pentru două dimensiuni putem folosi graficele de o singură dimensiune grupând datele noastre în funcție de variabilele ce reprezintă următoarele dimensiuni sau putem folosi grafice cu 2 axe.

Vom grupa datele în funcție de stație pentru valoarea poluantul $PM_{2.5}$ în boxplot-uri.

```
roPM_2_5 <- RoPollutionData2019[RoPollutionData2019$PolluantCode ==
    "6001", ]
boxplot(Value ~ as.character(ID), data = roPM_2_5)
```

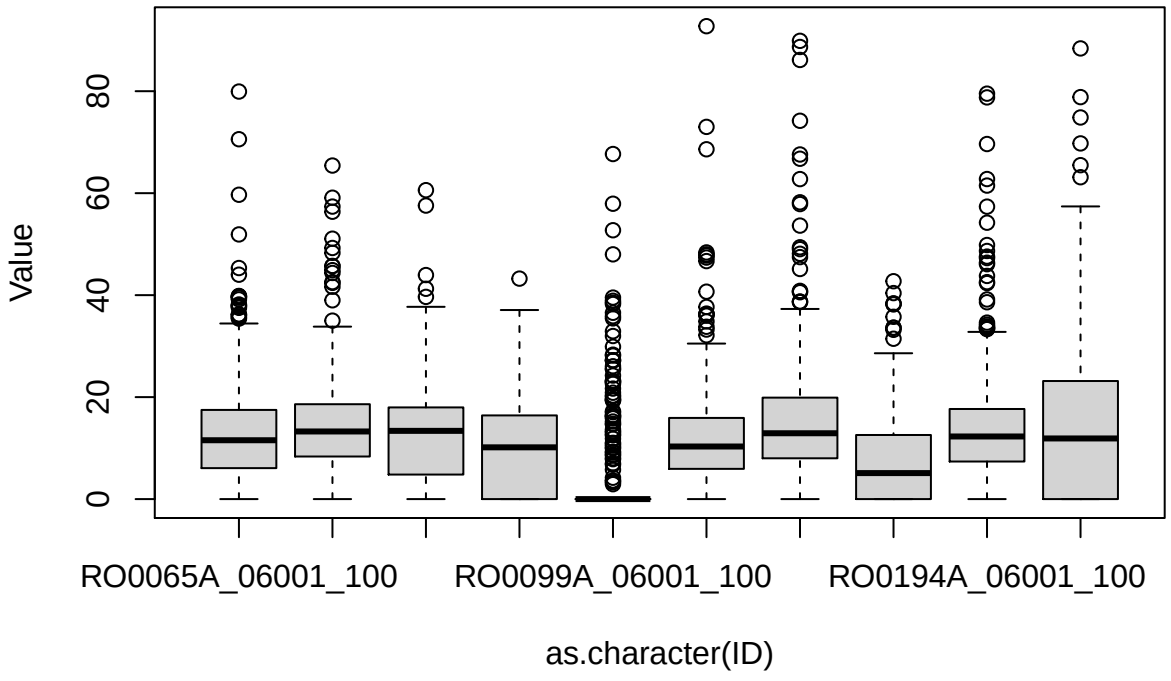

Putem folosi mai multe histograme pentru a afișa distribuția valoriilor pentru 2 stați.

```
par(mfrow = c(2, 1), mar = c(4, 4, 2, 1))
hist(subset(roPM_2_5, ID == "RO0099A_06001_100")$Value, breaks = 50)
hist(subset(roPM_2_5, ID == "RO0210A_06001_100")$Value, breaks = 50)
```

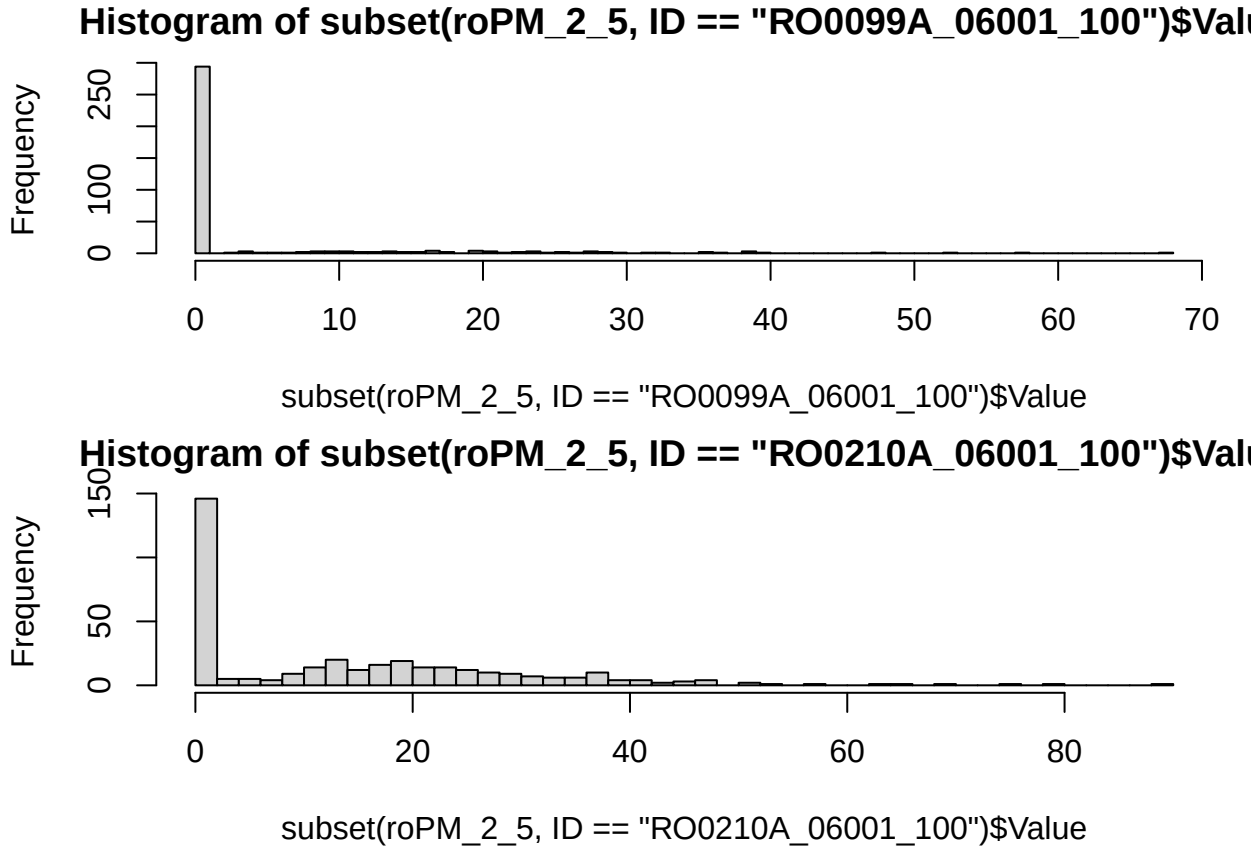

O altă metodă este de a explora legătura dintre 2 variabile continue.

```
plot(roPM_2_5$StartDate, roPM_2_5$Value)
```

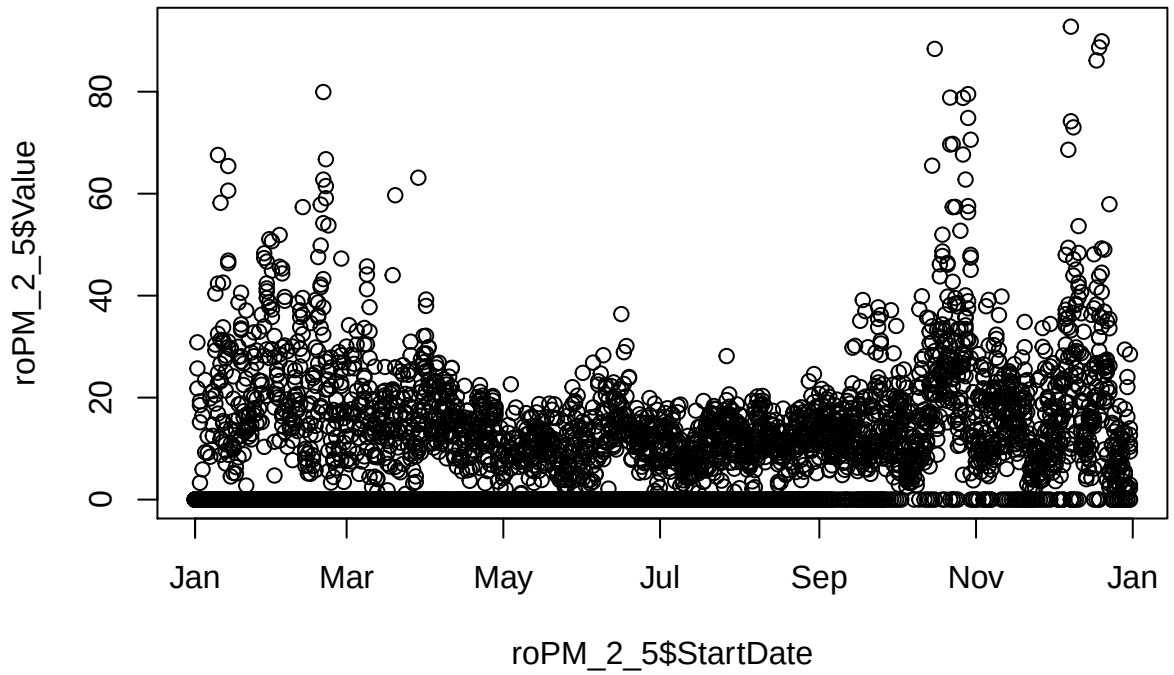

Putem adăuga o altă varaibilă print grupări sau colorarea punctelor. De exemplu mai jos afișăm cele două varaibile de timp și cea a valorii poluantului colorându-le în funcție de stație. Totuși nu știm ce reprezintă fiecare culoare.

```
plot(roPM_2_5$StartDate, roPM_2_5$Value, col = roPM_2_5$ID)
```

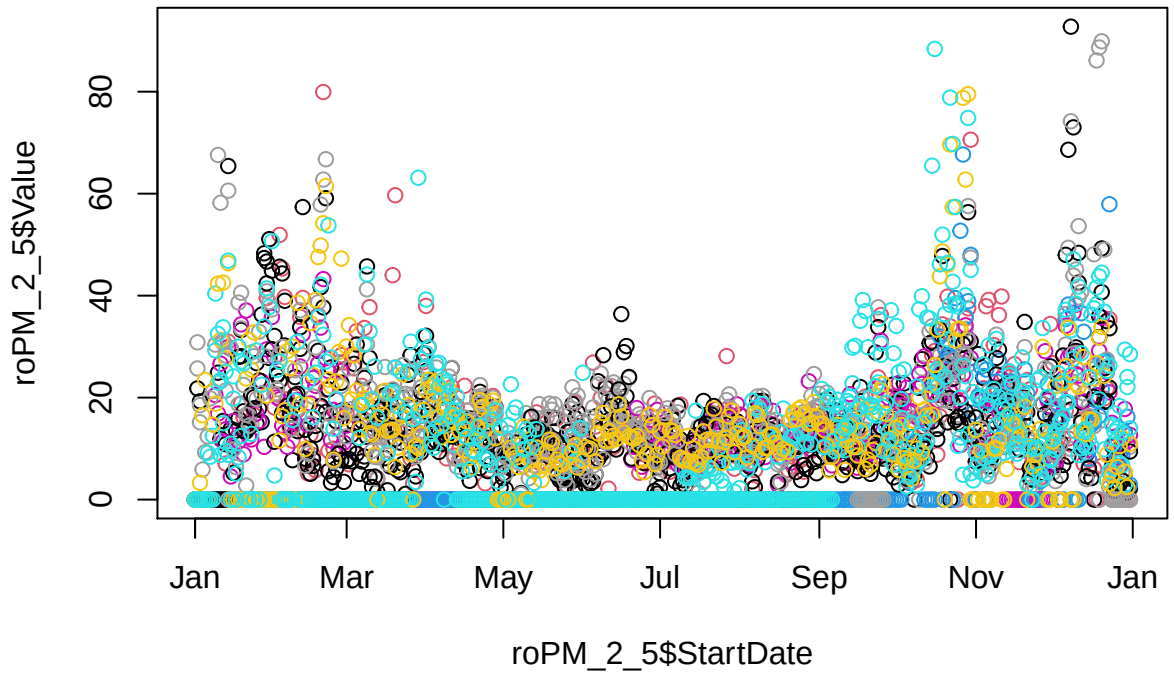


```
plot(roPM_2_5$StartDate, roPM_2_5$Value, col = roPM_2_5$ID, ylim = c(0,
    max(roPM_2_5$Value) + 40), bty = "L", xlim = c(min(roPM_2_5$StartDate),
    max(roPM_2_5$StartDate) + months(6)))
par(xpd = TRUE)
legend(max(roPM_2_5$StartDate) + months(1), max(roPM_2_5$Value) +
    40, legend = unique(roPM_2_5$ID), col = unique(roPM_2_5$ID),
```

```
    pch = 1)
```

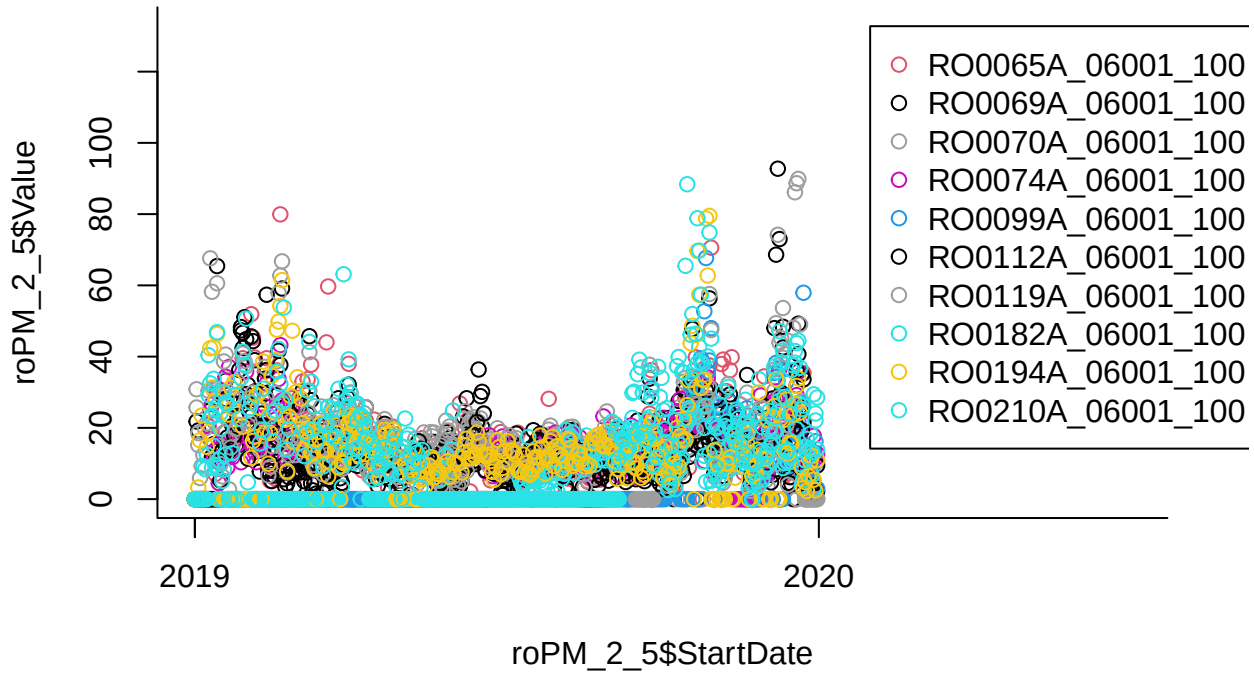

O altă metodă este de a separa graficul în mai multe grafice în funcție de a treia variabilă.

```
par(mfrow = c(1, 2), mar = c(5, 4, 2, 1))
with(subset(roPM_2_5, ID == "RO0099A_06001_100"), plot(StartDate,
    Value))
with(subset(roPM_2_5, ID == "RO0210A_06001_100"), plot(StartDate,
    Value))
```

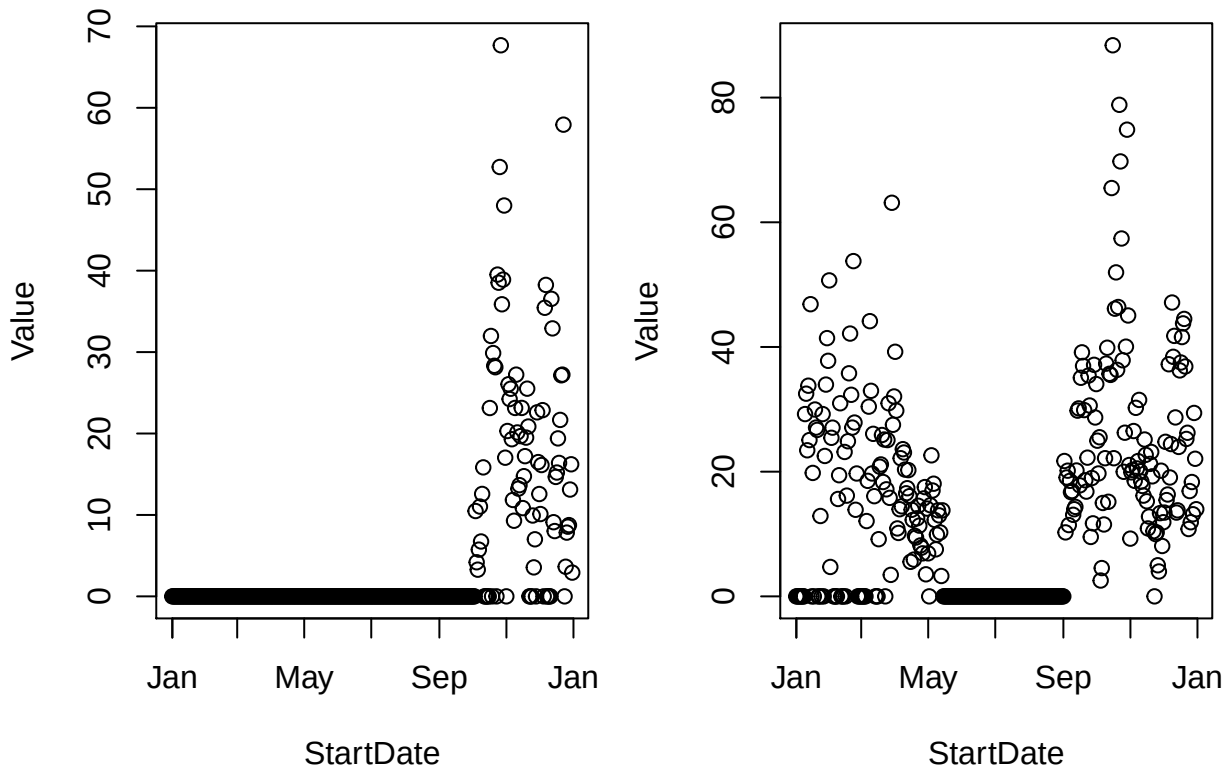

Sisteme Grafice în R

În R sunt 3 sisteme grafice principale: base, lattice și ggplot2. Base este sistemul grafic de bază, care folosește modelul artistului, ce îl face o opțiune bune pentru graficele de explorare. Principiul este simplu faci graficul inițial cu date. Peste acesta poți afăuga rând pe rând diferite obiecte grafice ajutăroare precum linii, regresi, puncte. Însă nu ai opțiunea de a merge înapoi în acțiuni. Dacă ai greșit va trebui să o iei de la capăt. Este intutiv și poți merge în detaliu cu explorarea.

Lattice este un sistem prin care graficul este făcut cu o singură funcție și necesită multe detalii. Se folosește când avem date condiționate și este necesar să avem un număr mar de grafice într-o singură figură. Din păcate graficul nu poate fi modificat după. Însă sumedenia de valori implicite îl face foarte atractiv pentru afișare și analiză.

ggplot2 este un sistem este bazat pe gramtica teroretică a graficelor și conține compenente din ambele sisteme prezentate anterior. Se pot adăuga pe rând informați în grafic și are valori implicite ce ajută în formatare.

Base System

Sistemul de bază din R folosește biblotecile graphics pentru grafice (plot,hist,boxplot) și grDevices pentru afiare poate fi ecranul sau documente specifice (ex: pdf, png). Înainte de a implement orice grafic trebuie să trecem prin gândire următaorele întrebări. - Unde va fi afiașt graficul ? Pe ecran într-un fișier ? În funcție de răspuns va trebui să setăm dispozitivul grafic. Pe lângă anumite sisteme grafice au proprietăți mai bune pe anumite dizpozitive grafice (ex base pe ecran, lattice imagine și web, ggplot2 documente printate). Dacă vom folosim graficul în prezentare este recomandat să avem un font mai mare. Dacă folosim graficul pentru publicare este recomandat să luăm în calcul o afișare alb-negru. - Pentru ce folosim graficul ? temporar pentru explorare sau pentru publicare/analiză. Pentru explorare de base este suficient și recomandat, însă pentru analiză celalte două sisteme grafice sunt mai avantajoase. - Vom avea un număr mare de puncte ? ggplot2 se descurcă la afiașarea unui număr mare de puncte, în timp ce lattice este maia vatanjos pentru un număr mai mare de grafice cu puține puncte și condiționate de varaibile. - Va trebuie să redimensionezi dinamic graficul ? Pentru redimensiunare contează formatul de fișier în care va fi salvat graficul. Formatul vectorial este mai avantajos.

Sistemul grafic de bază este folosit în mare parte pentru formarea graficelor bidimensionale și conține 2 etape: inițializarea graficului și adnotarea lui cu elemente specifice. Inițializarea graficului se face cu una din funcțiile (plot, hist, barplot, boxplot) și va porni un dispozitiv grafic implicit (dacă nu este setat deja unul). Inițializarea introduce sistemul de axe, limitele și punctele inițiale. Acestea pot fi setate prin parametri pentru funcția inițială. Ei pot fi observați cu ajutorul:

```
`?`(par)
```

Vom trece prin funcțiile de inițializare. Vom folosi datele pentru o singură stație și poluantul $PM_{2.5}$.

```
roPM_2_5_RO0119A <- subset(roPM_2_5, ID == "RO0119A_06001_100")
```

```
hist(roPM_2_5_RO0119A$Value)
```

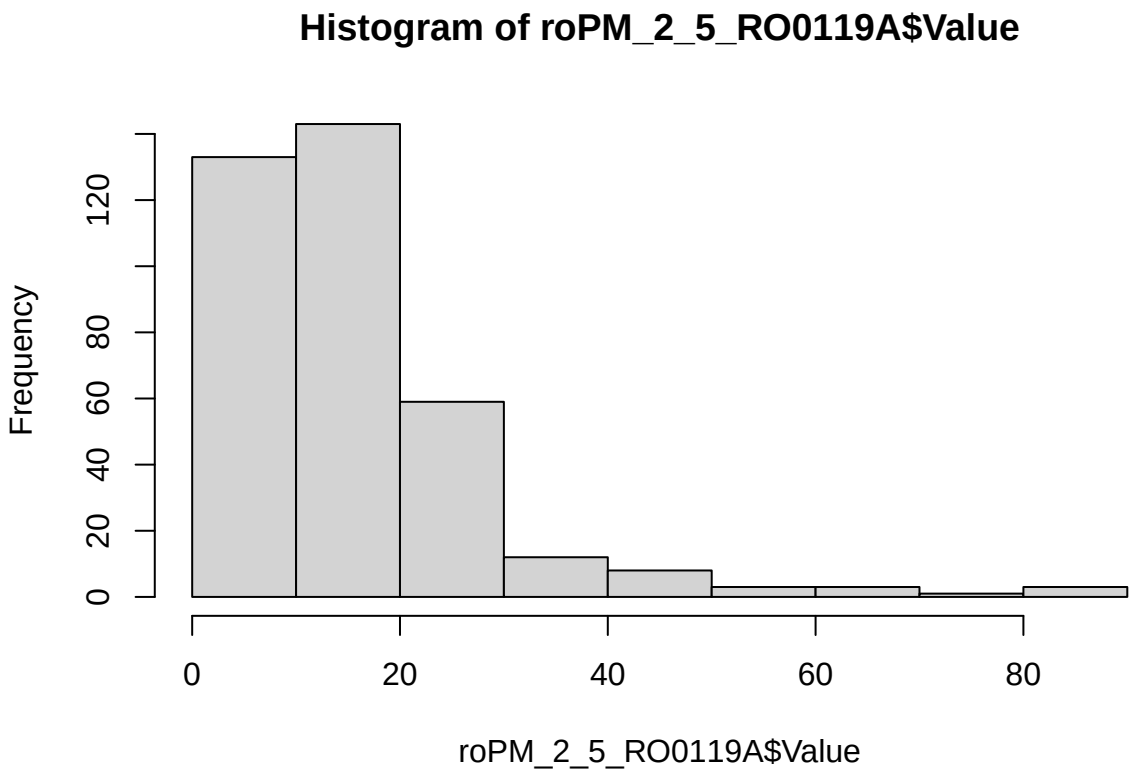


```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value)
```

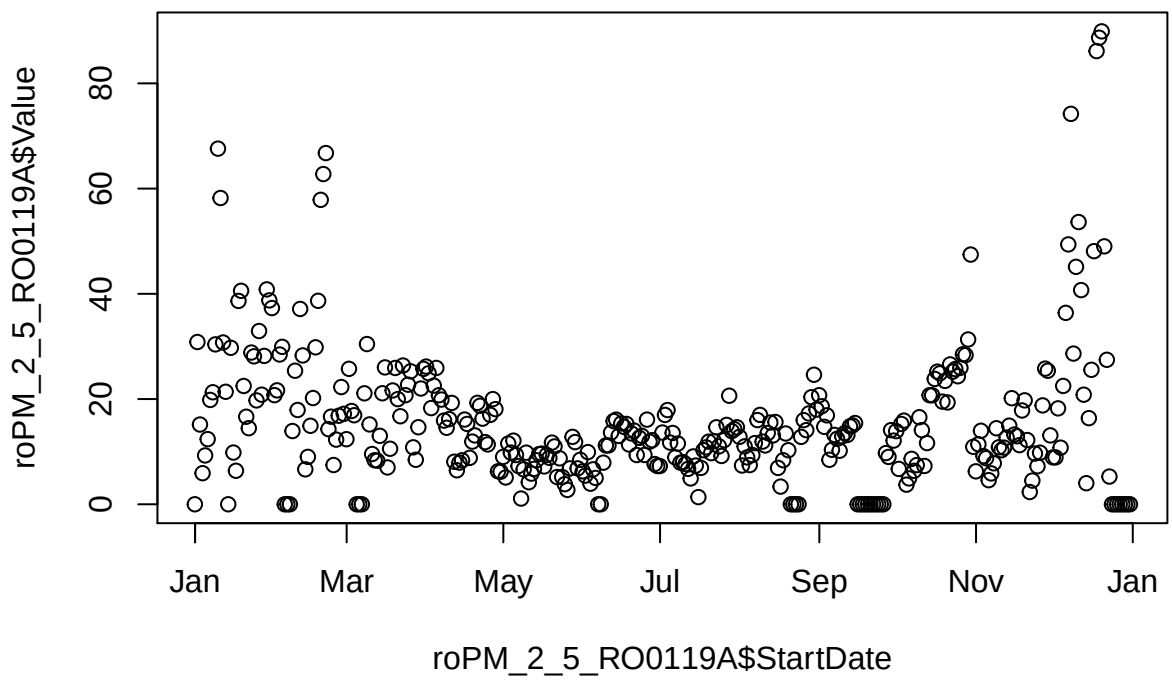


```
roPM_2_5_RO0119A_month <- roPM_2_5_RO0119A %>% transform(Month = factor(month(roPM_2_5_RO0119A$StartDat
boxplot(Value ~ Month, roPM_2_5_RO0119A_month, xlab = "Month",
    ylab = "PM_2_5")
```

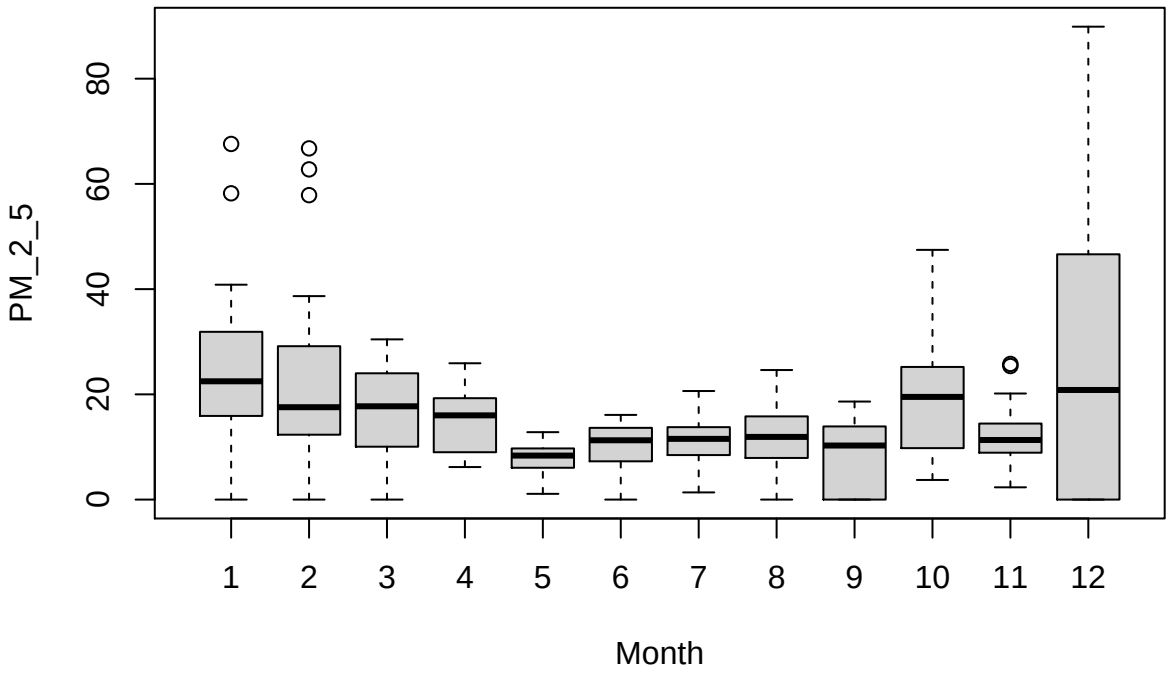

Mai sus am modificat 2 parametrei impliciti xlab și ylab. Parametrii ce pot fi modificați în cadrul funcției de inițializare a datelor sunt: - pch - se referă la formatul punctelor. Implicit este un cerc deschis.

```
# example(points)
```

- lty - se referă la tipul de linie folosit. Implicit e solidă, dar poate fi punctată sau tăiată. Depinde de unde va fi afișat graficul: Pe o presentare powerpoint nu e inidcat să ai tipuri diferite de linii ci să le diferențiezi cu ajutorul culoriilor; În cazul articolelor care ajung într-un formt alb-negru este mai indicat să folosești tipul liniei decât culoarea.
- lwd - lățimea unei linii. Pentru o prezentare este recomandată o valoare mai mare.
- col - culoarea. În articole trebuie să fim atenți de modul cum vor fi percepute în alb-negru culoriile. Se recomandă folosirea unei palete de culori.
- xlab,ylab - denumiriile axelor
- type - Setează tipul graficului. Poate avea următoarele valori:
  - type="P" - pentru puncte valoarea implicită

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "p")
```

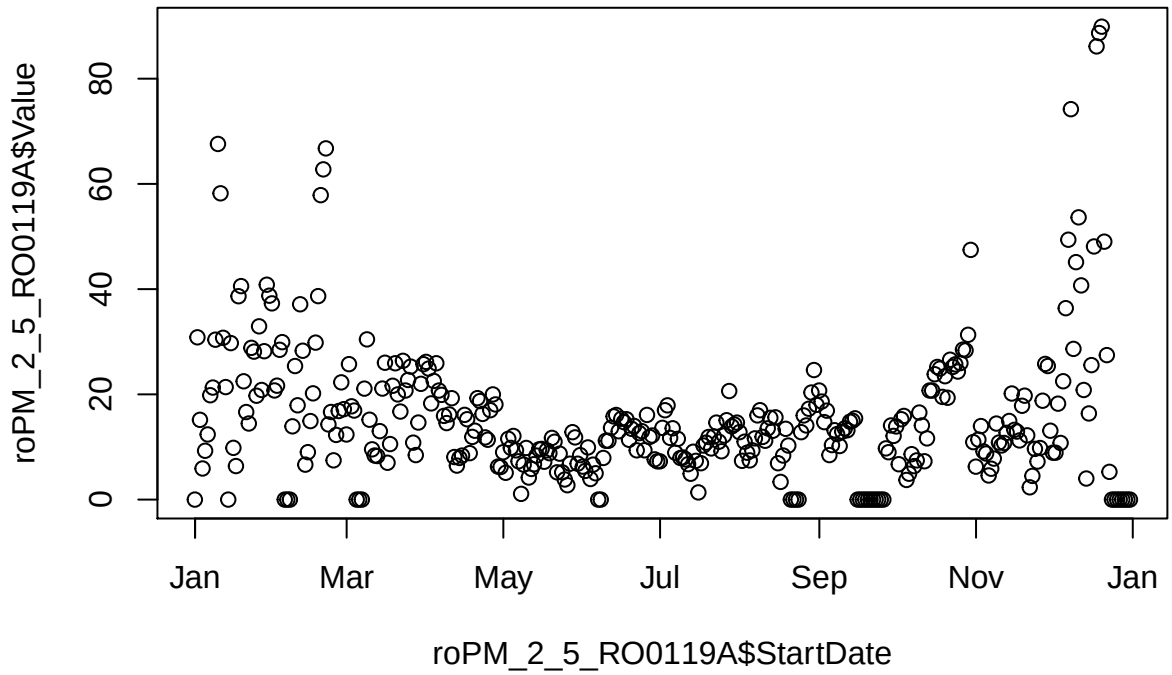

type="l" - pentru linii

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "l")
```

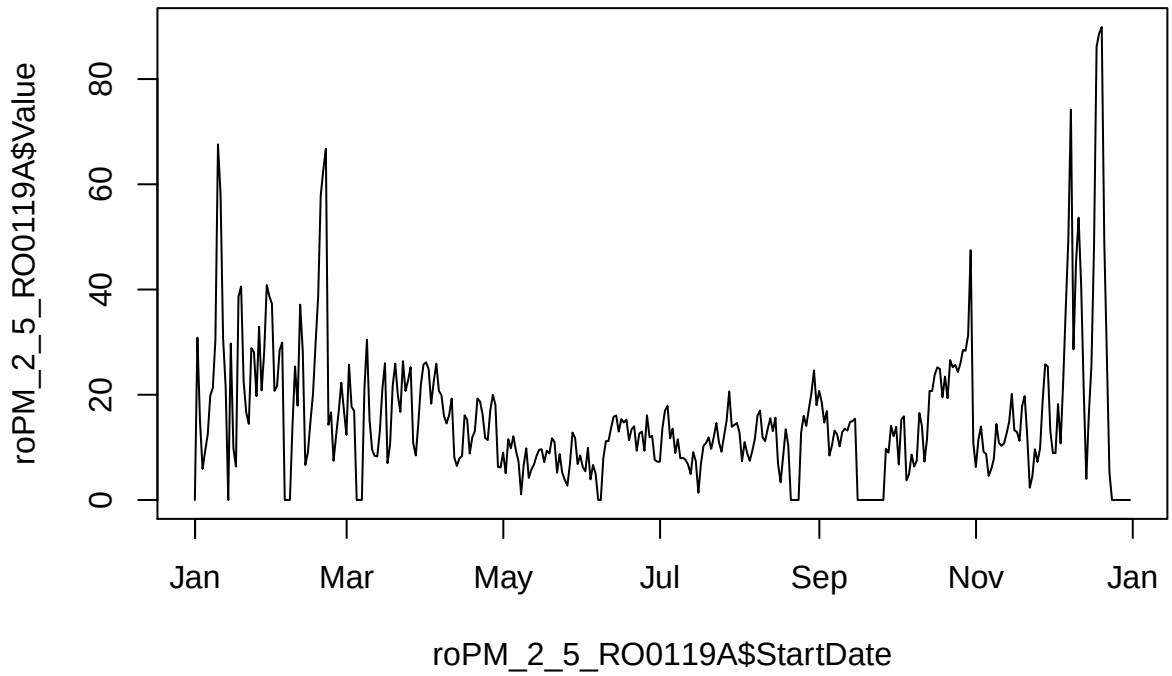

type="b" - pentru puncte și linii care nu se suprapun

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "b")
```

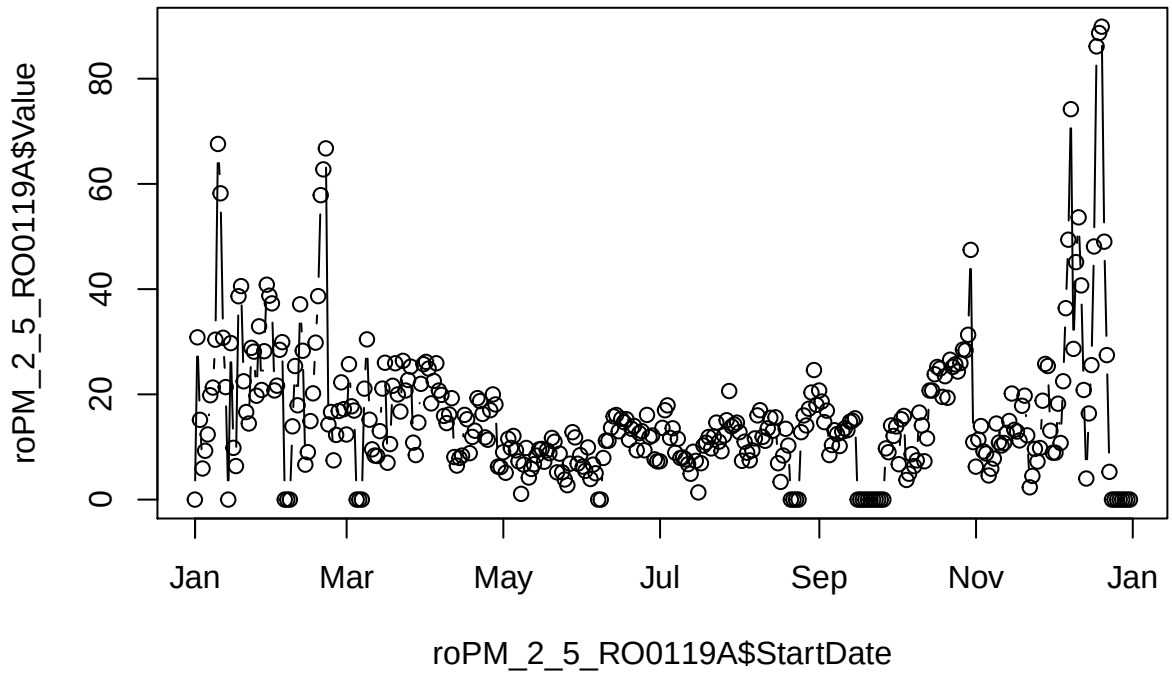

type="o" - pentru puncte și linii care se suprapun

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "o")
```

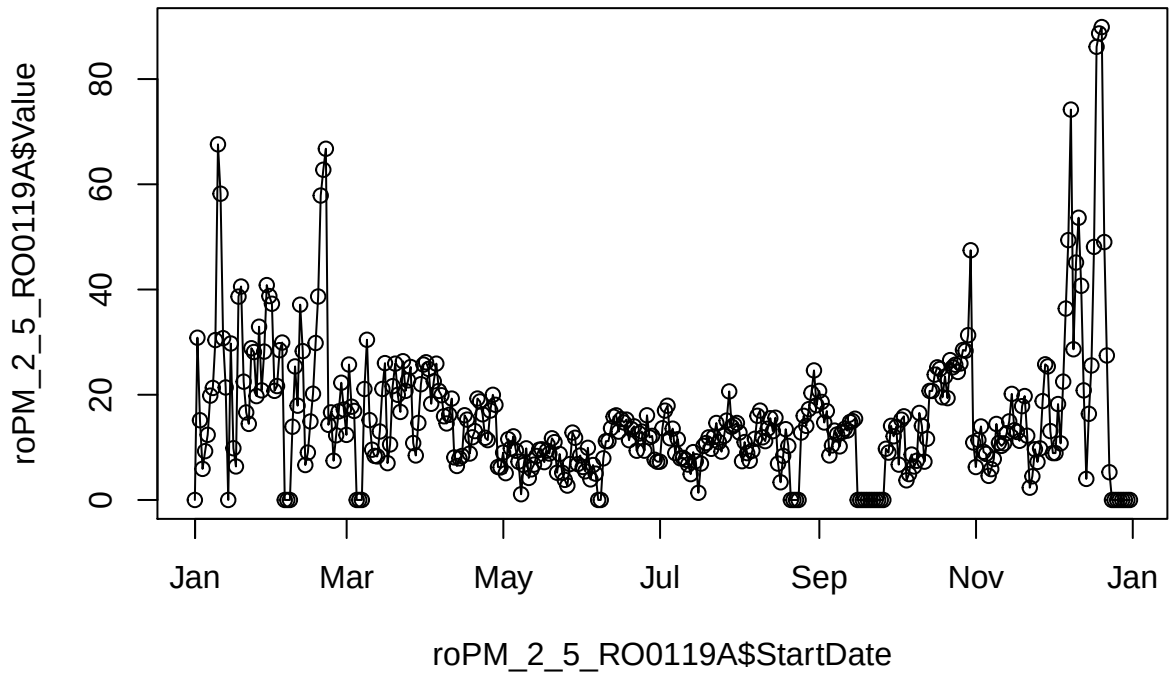

type="h" - pentru histograma (doar modul de afișare)

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "h")
```

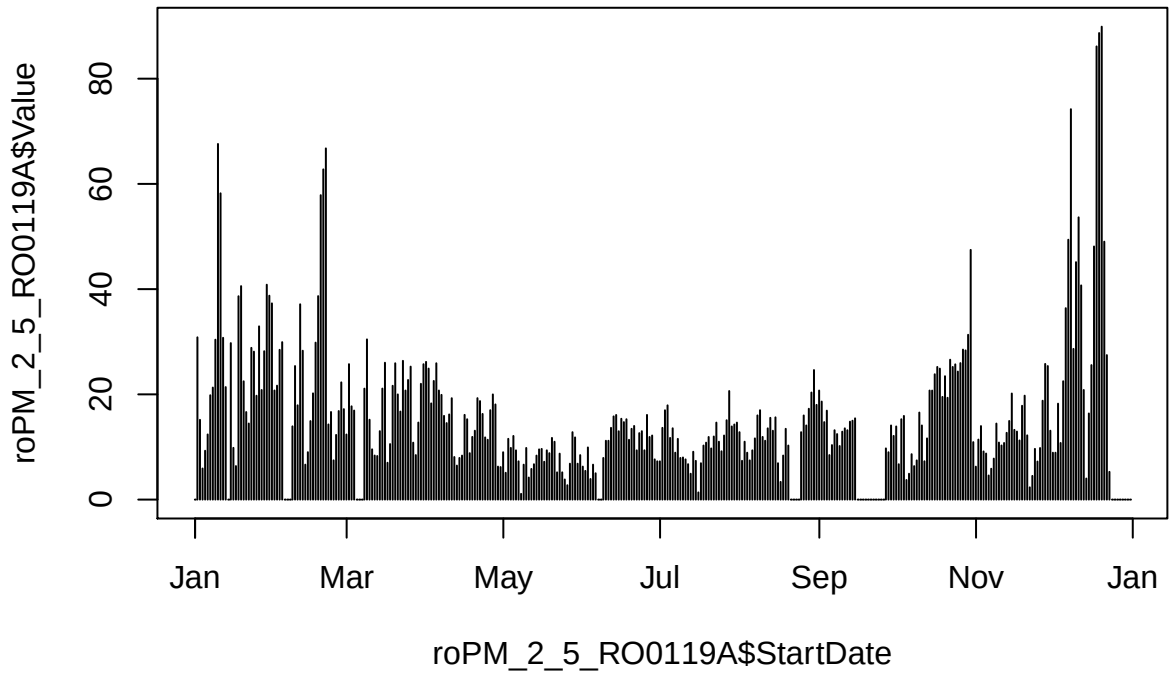

type="s" - pentru tipul "scară"

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "s")
```

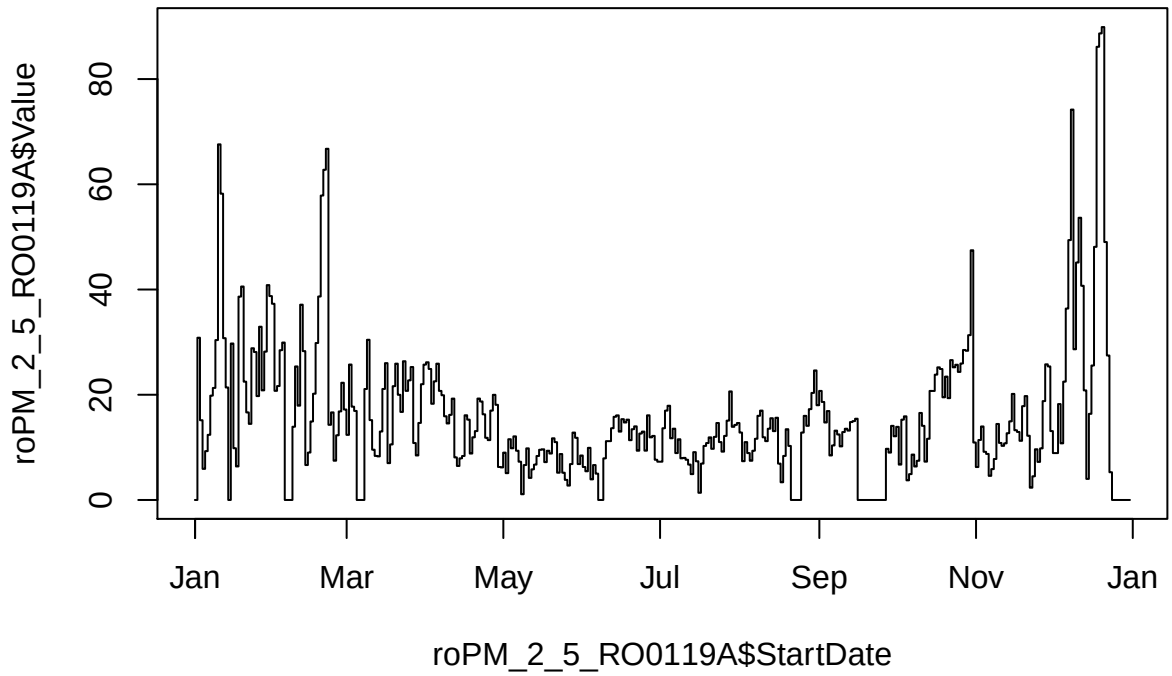

type="n" - doar inițializează axele și sistemul de coordonate

```
plot(roPM_2_5_RO0119A$StartDate, roPM_2_5_RO0119A$Value, type = "n")
```

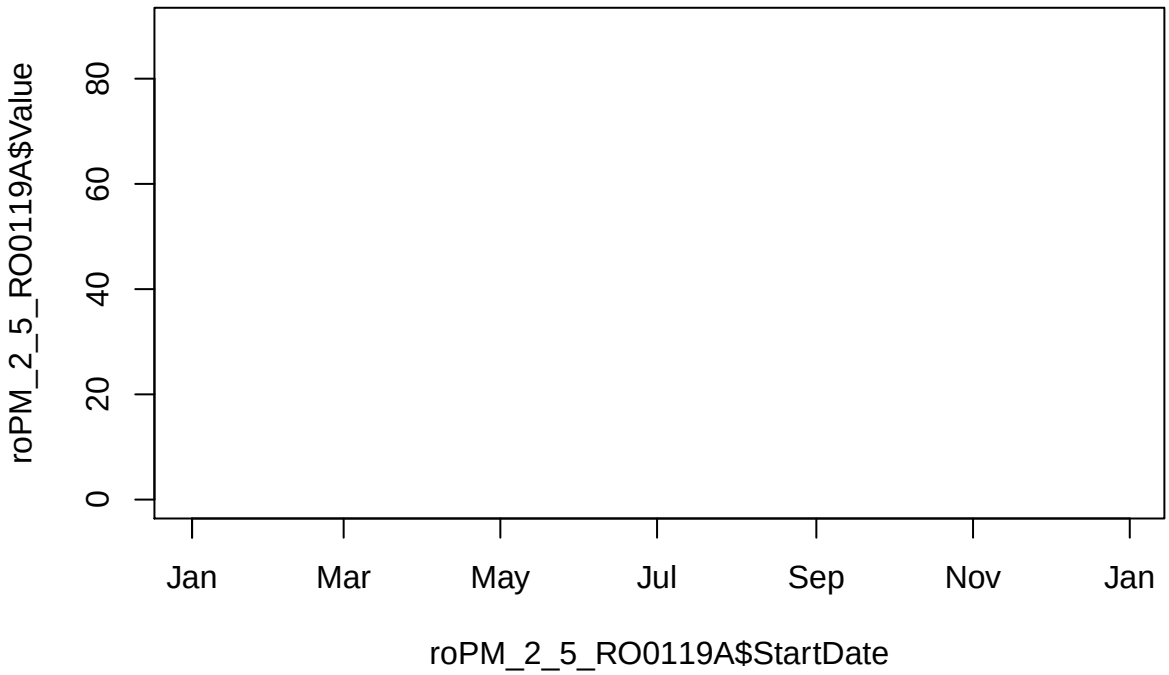

Prin funcția par() putem seta următorii parametri globali pentru dizpozitivul grafic curent: - las - orientarea axelor - bg - culoarea de background - mar - dimenziuniile mariginii pentru sistemul de axe (Jos, Stânga, Sus, Dreapta) - oma - dimensiuniile marginiil pentru grafic - mfrow - numărul de grafice pe rând, coloană - se completează rânduriile prima data - nfcol - numărul de grafice pe coloană, rând - se completează coloanele prima dată

Adnotării prezente în sistemul grafic de bază: - lines - points - text - title - mtext - axis

Dispozitive Grafice Limbajul R are trei tipuri de dipozitive grafice: - Ecranul. Depinde de sistemul de operare pe care îl ai și de numărul de ecrane. Este dizpozitivul implicit și se manifestă printr-o fereastră cu graficul. - Fișiere de tip vector. Advantaje: portabilitate, redimensionare. Dezavantaje: nu pot avea foarte multe puncte. - pdf - svg - postrcript - Fișiere de tip bitmap. Advanataje: bun pentru multe puncte. Dezavantaj: redimensionare - png - jpeg - tiff - bmp

Deschiderea unui dispozitiv grafic

```
# pdf(file='myplot.pdf') plot... dev.off()
```

Copiere -

```
# plot... dev.copy(png, file='myplot.png') dev.off()
```

Latice System

Al doilea sistem grafic din R este Lattice. Acesta este concentrat pe grafice cu o densitate mare de puncte. Față de celelate sisteme tot graficul este creat cu un singur apel de funcție, ce conține o variate mare de valori implicite care ajută în formatarea lor înlocuind multe din funcțiile sistemului grafic de bază. Un dezavantaj vizibil este că nu putem face adnotări graficelor, fiind necesară refacerea lui dacă vrem să modifică/adăugam informații. Din această cauză acest sistem grafic nu este folosit pentru grafice de explorare. Utilitatea lui este de formare a graficelor de analiză când știim deja ce date vrem să afișăm și modul în care dorim să le afișăm.

Funcțiile prinicpale în sistemul grafic Lattice sunt: - xyplot - pentru grafice simple pe două dimensiuni - bwplot - boxplot - histogram - stripplot - asemănător bwplot dar cu puncte - dotplot - renumitul grafic

“vioară” - splom - grafice în matrice (TODO: autorul a jucat CS, puteți folosi link-ul [http://www.unige.ch/ses/sococ/cl/r/scatmat.e.html] - slabe șanse să vă fie util) - levelplot, contourplot - pentru imagini

Primul argument pentru funcțiile din sistemul Lattice este o formulă. Formula este într-un format statistic, de aici și utilizarea acestui sistem în rândul persoanelor cu afinități statistice. “Egalul” din formulă este reprezentat de caracterul “~”. Caracterul “|” reprezintă dependența și duce la împărțirea datelor în funcție de câmpuriile date. Acest lucru duce și la crearea câte unui grafic pentru fiecare grupare. Caracterul “|” este opțional. Între “~” și “|” se află variabilă pentru axa oX.

```
xyplot(Value ~ month(StartDate) | ID, data = RoData2019_PM_2_5)
```

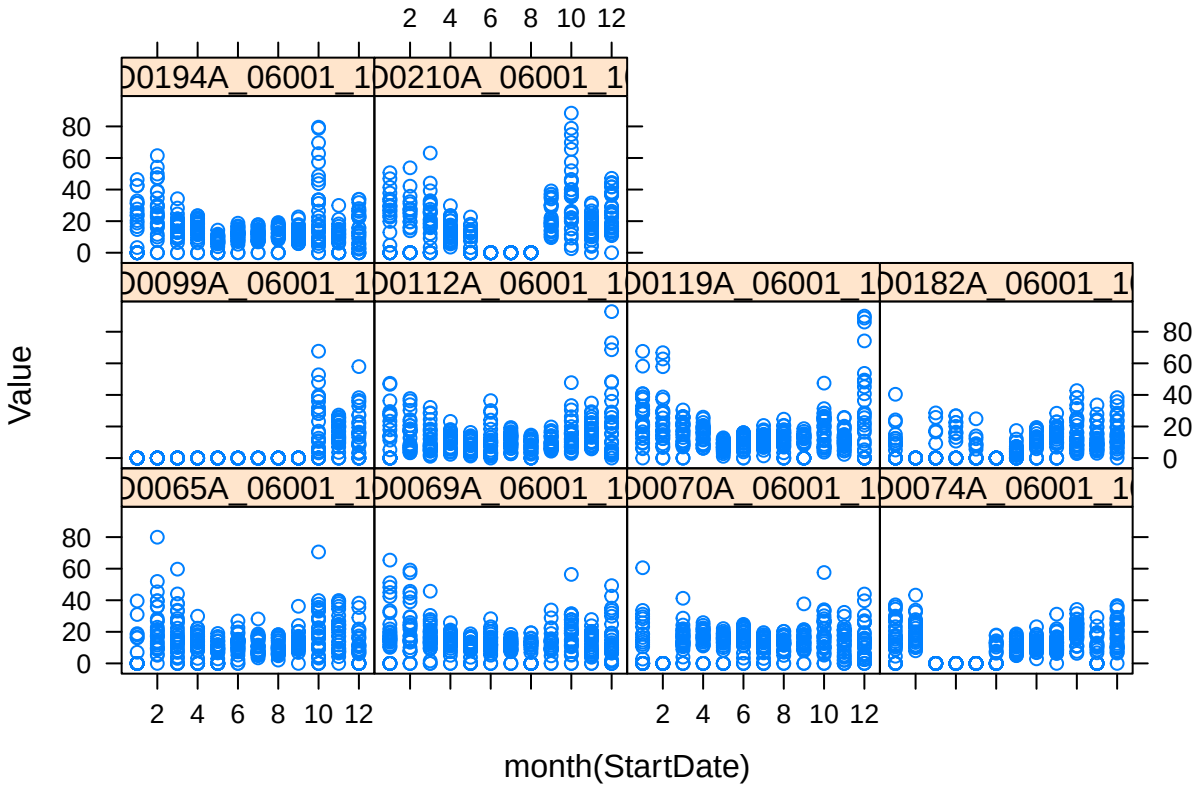

În cazul în care avem mai multe grupuri de date și dorim să controlăm structura de afișare putem utiliza paramatreul layout.

```
xyplot(Value ~ month(StartDate) | ID, data = RoData2019_PM_2_5,
    layout = c(2, 5))
```

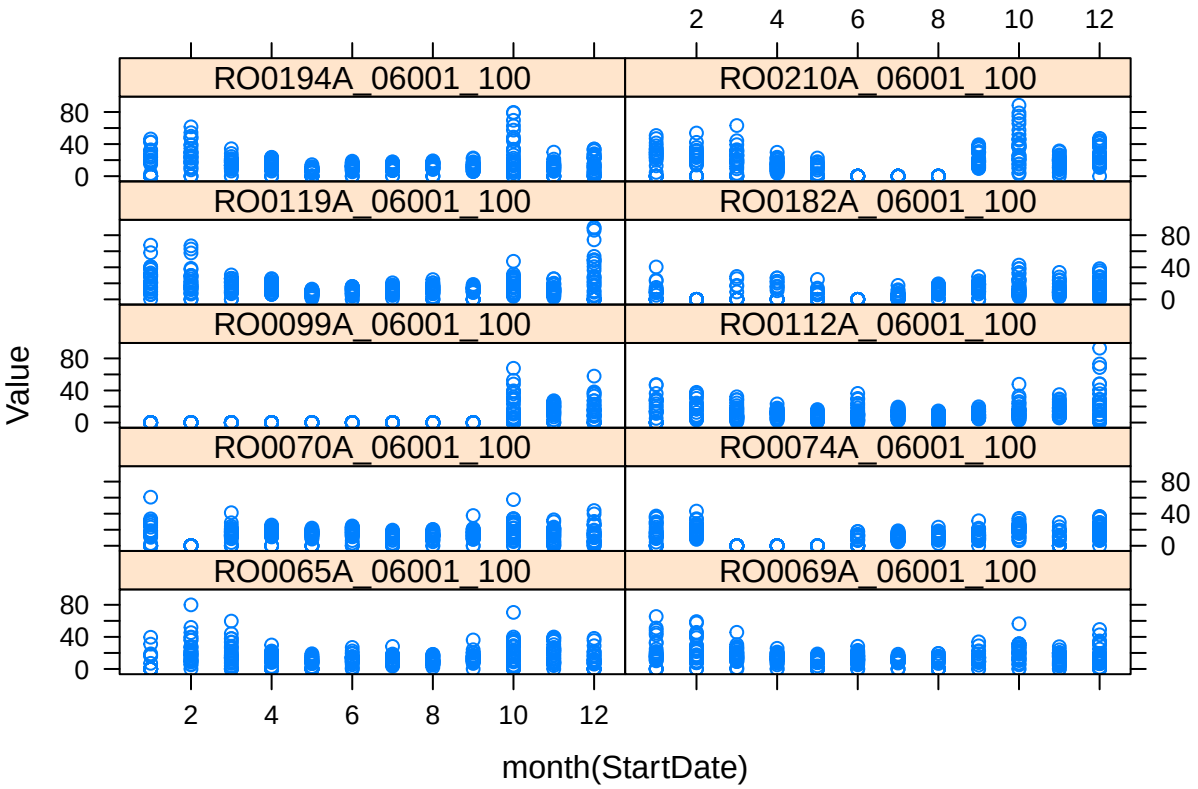

Funcțiile din Lattice returnează un obiect a carui funcție print returnează graficul văzut de noi.

```
a <- xyplot(Value ~ month(StartDate) | ID, data = RoData2019_PM_2_5)
print(a)
```

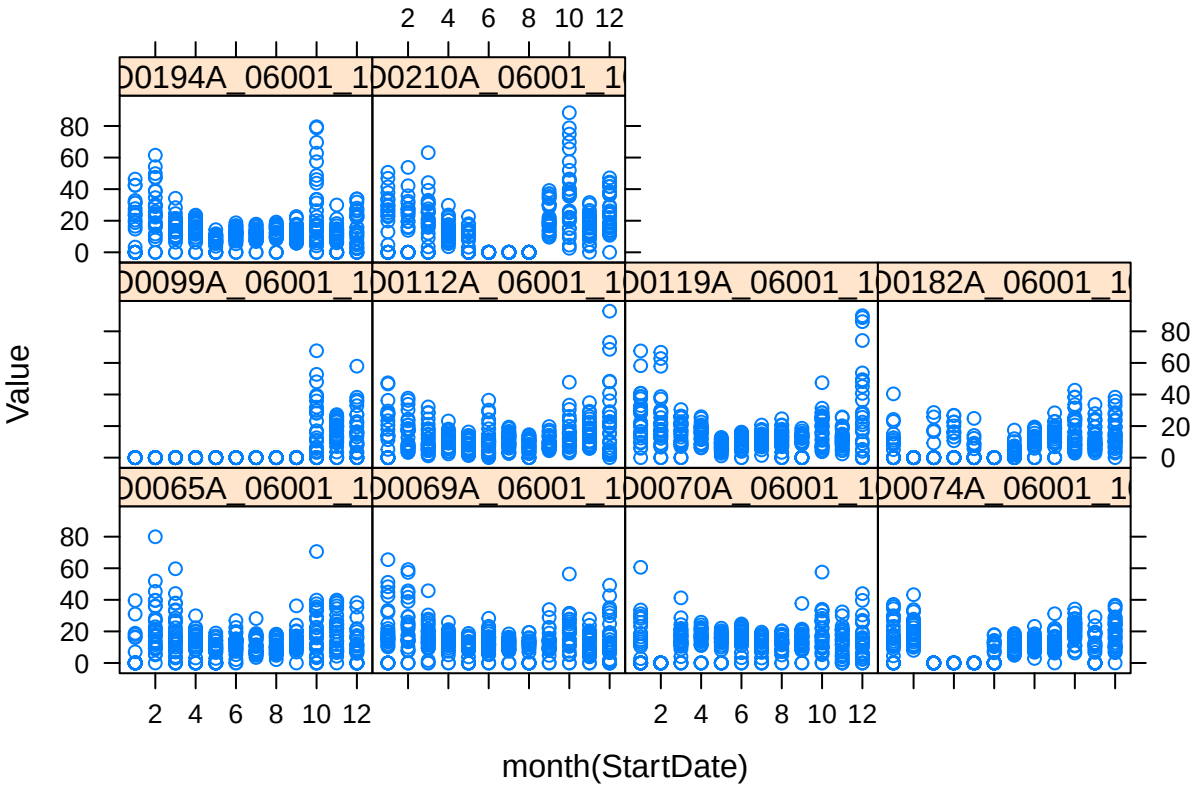

O altă funcționalitate din sistemul grafic Lattice pentru grupuri de date este acela de a putea controla fiecare grafic cu funcții panel.

```
xyplot(Value ~ month(StartDate) | ID, data = RoData2019_PM_2_5,
    panel = function(x, y, ...) {
        panel.xyplot(x, y, ...)
        panel.abline(h = median(y), lty = 2)
        panel.lmline(x, y, col = 2)
    })
```

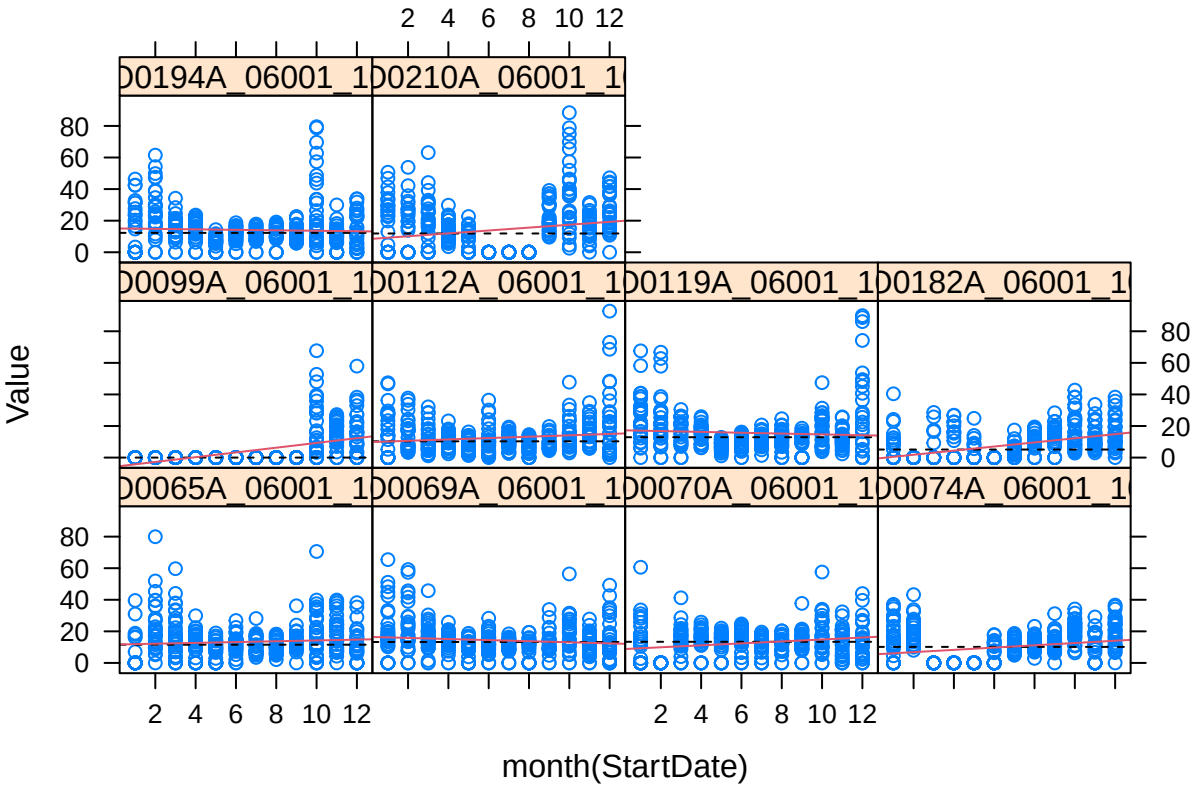

Ggplot2 System

Al treilea sistem grafic din R este ggplot2. Acesta are ca inspirație lucrarea "Grammar of graphics" de Leland Wilkinson [https://www.springer.com/gp/book/9780387245447]. Teza conceptului definit în carte este de a "scurta distanța de la minte la grafic pe pagină" prin transformarea conceptelor grafice în verb, substantiv sau adjectiv. O scurtă definiție din carte: " In brief, the grammar tells us that a statistical graphic is a mapping from data to aesthetic attributes (colour, shape, size). The plot may also contain statistical transformations of the data and is drawn on a specific coordinate system"

Din asta putem extrage principale componente din ggplot2: - data - datele de intrare date de noi. Obligatoriu să fie de tipul data.frame . - aesthetic attributes - atribute pentru datele noastre în grafic. Vom observa că sunt setate prin folosirea funcției aes. - geoms - sunt în general obiecte grafice ce vor apărea în grafic precum puncte, linii sau poligoane. - facets - În caz de avem grafice condiționante de anumite variabile și dorim să le împărțim în grupuri. - stats - transformări statistice precum: cuantile sau regresii. - scales - atribute globale care afectează "aesthetic attributes". - coordinate system - sistemul de coordonate.

Toate aceste componente sunt setate separat și specific.

Ggplot2 utilizează două modele diferite: unul asemănător sistemului lattice prin funcția qplot și celălalt asemănător sistemului grafic de bază print utilizarea ggplot2 și unor funcții predefinite.

qplot qplot este o funcție asemănătoare funcțiilor de bază din sistemul lattice doar că utilizează în detrimentul celor statistice.

În mod implicit parametrii suplimentari pentru qplot sunt considerați atribute pentru datele data. Primi 2 parametri sunt valoriile pe axa oX și axa oY.

```
qplot(StartDate, Value, data = RoData2019_PM_2_5, color = ID)
```

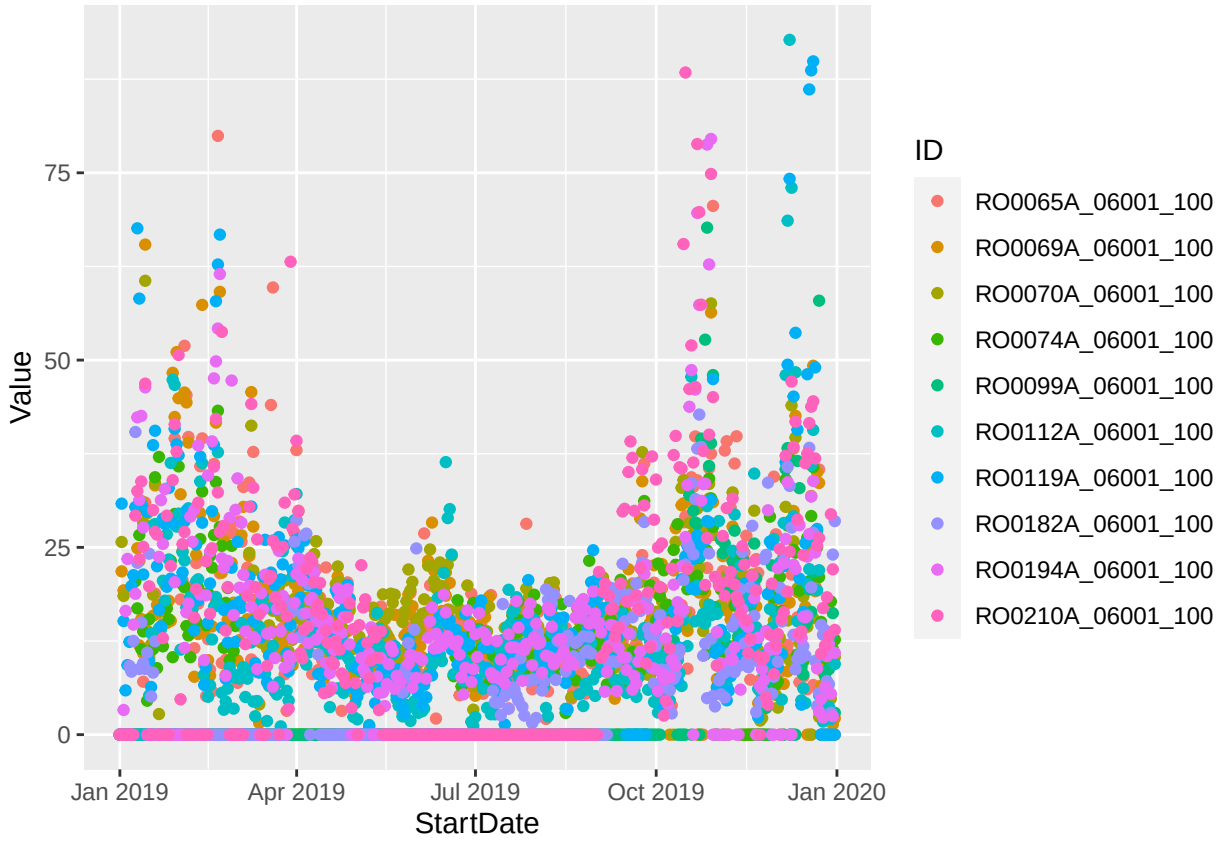


```
qplot(displ, hwy, data = mpg, color = drv)
```

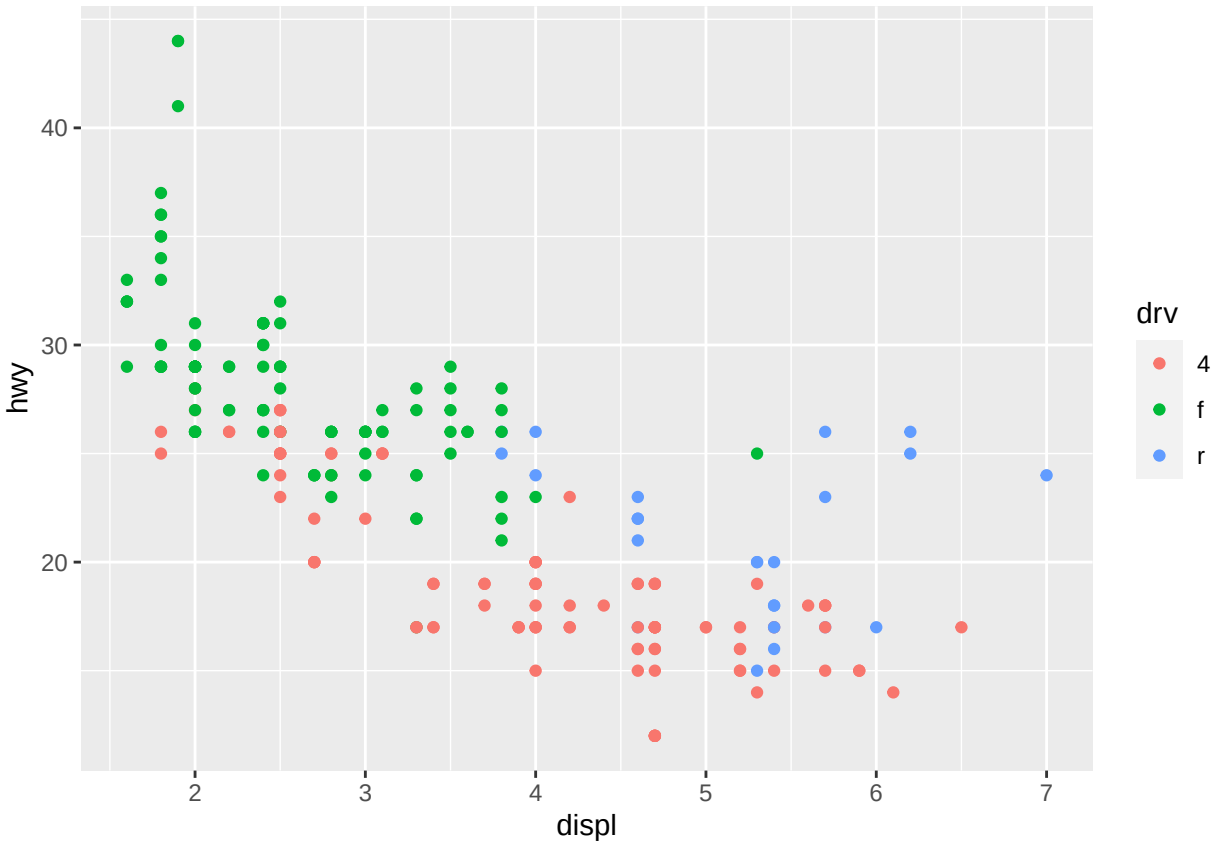

Pentru a adăuga diferite obiecte grafice este necesară precizarea lor prin parametrul geom.

```
qplot(StartDate, Value, data = RoData2019_PM_2_5, geom = c("point",
    "smooth"))
```

```
## `geom_smooth()` using method = 'gam' and formula 'y ~ s(x, bs = "cs")'
```

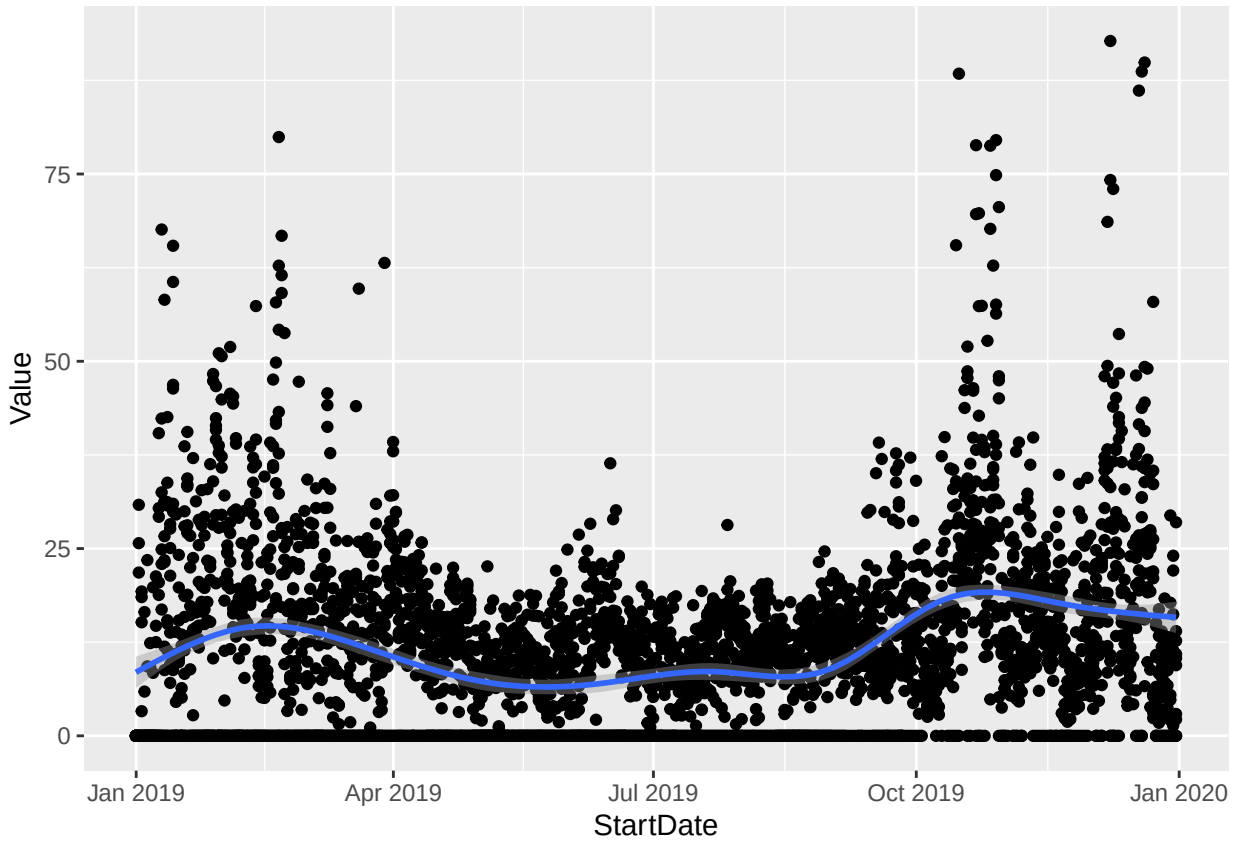


```
qplot(displ, hwy, data = mpg, geom = c("point", "smooth"))
```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

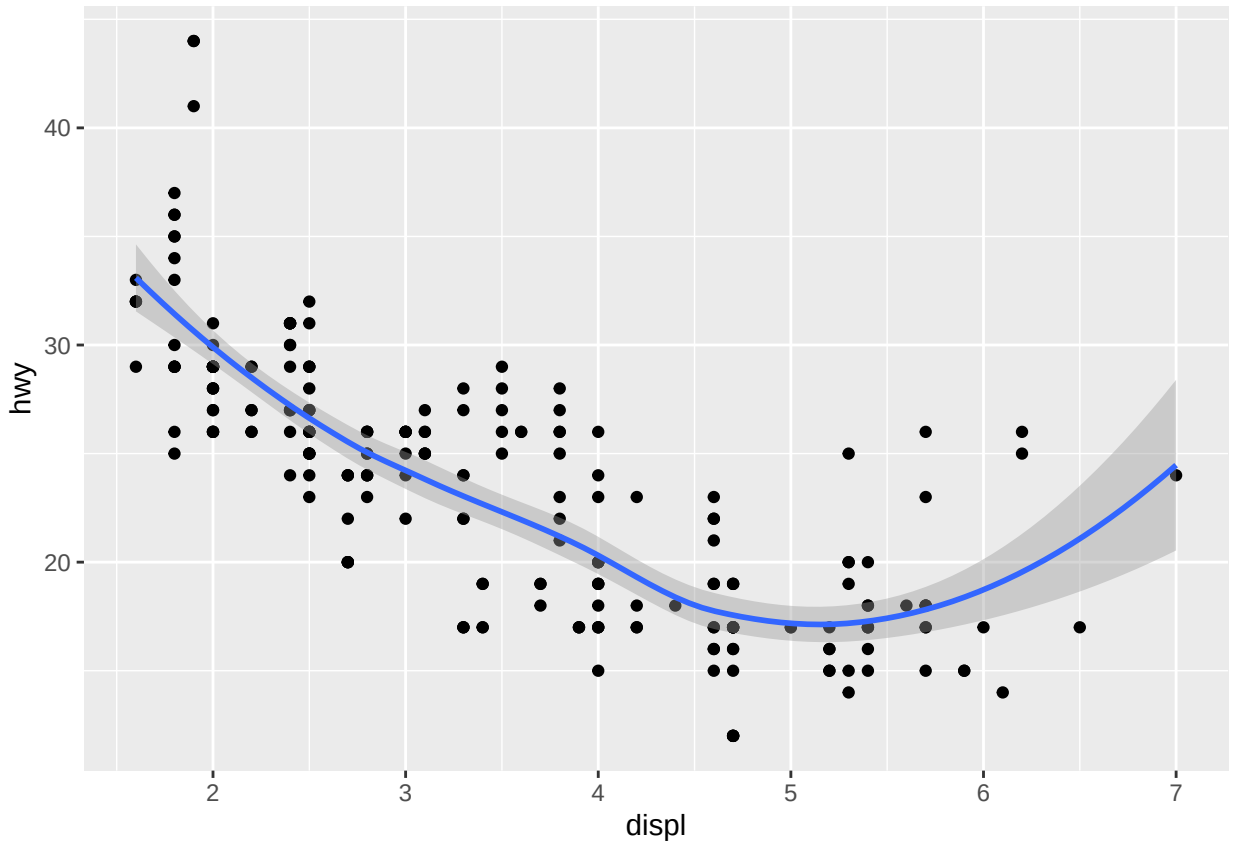

În caz de precizăm doar o singură axa va fi utiliză o histogramă.

```
qplot(Value, data = RoData2019_PM_2_5, fill = ID)
```

```
## `stat_bin()` using `bins = 30`. Pick better value with `binwidth`.
```

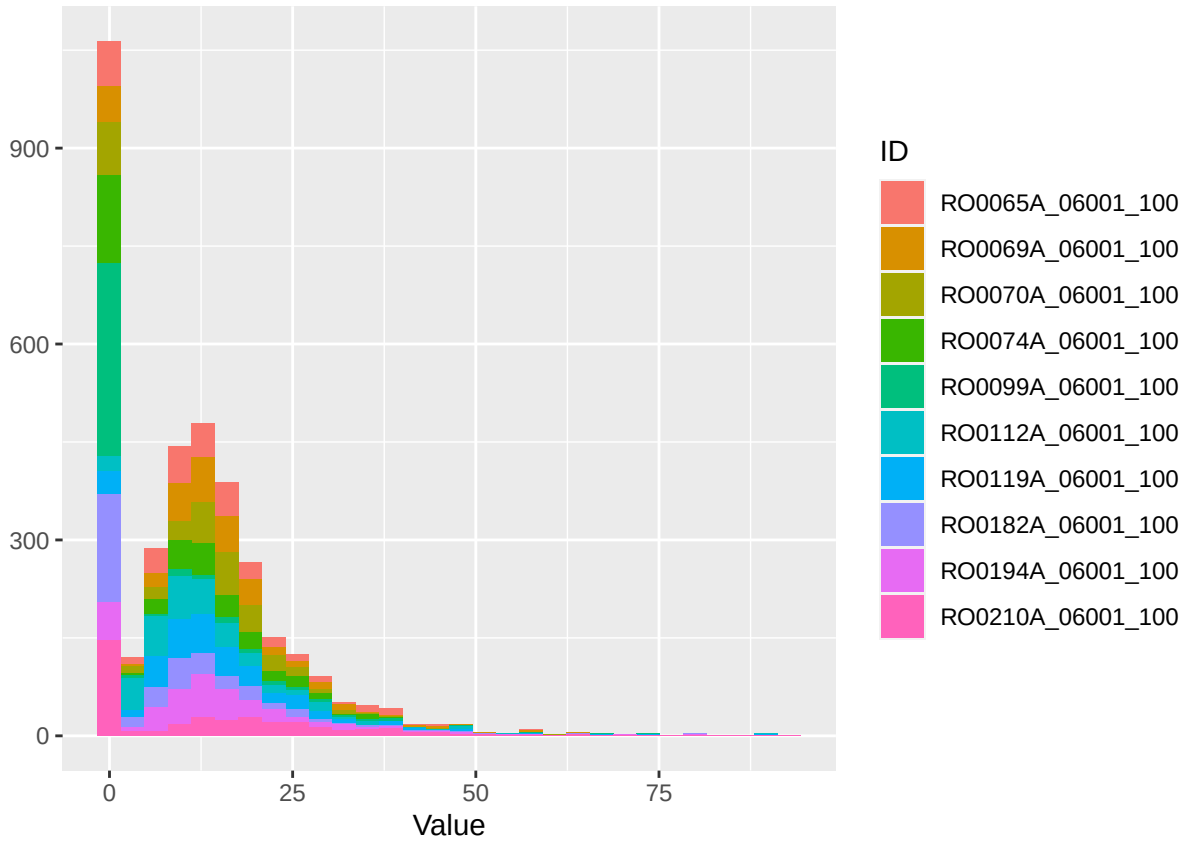


```
qplot(hwy, data = mpg, fill = drv)
```

```
## `stat_bin()` using `bins = 30`. Pick better value with `binwidth`.
```

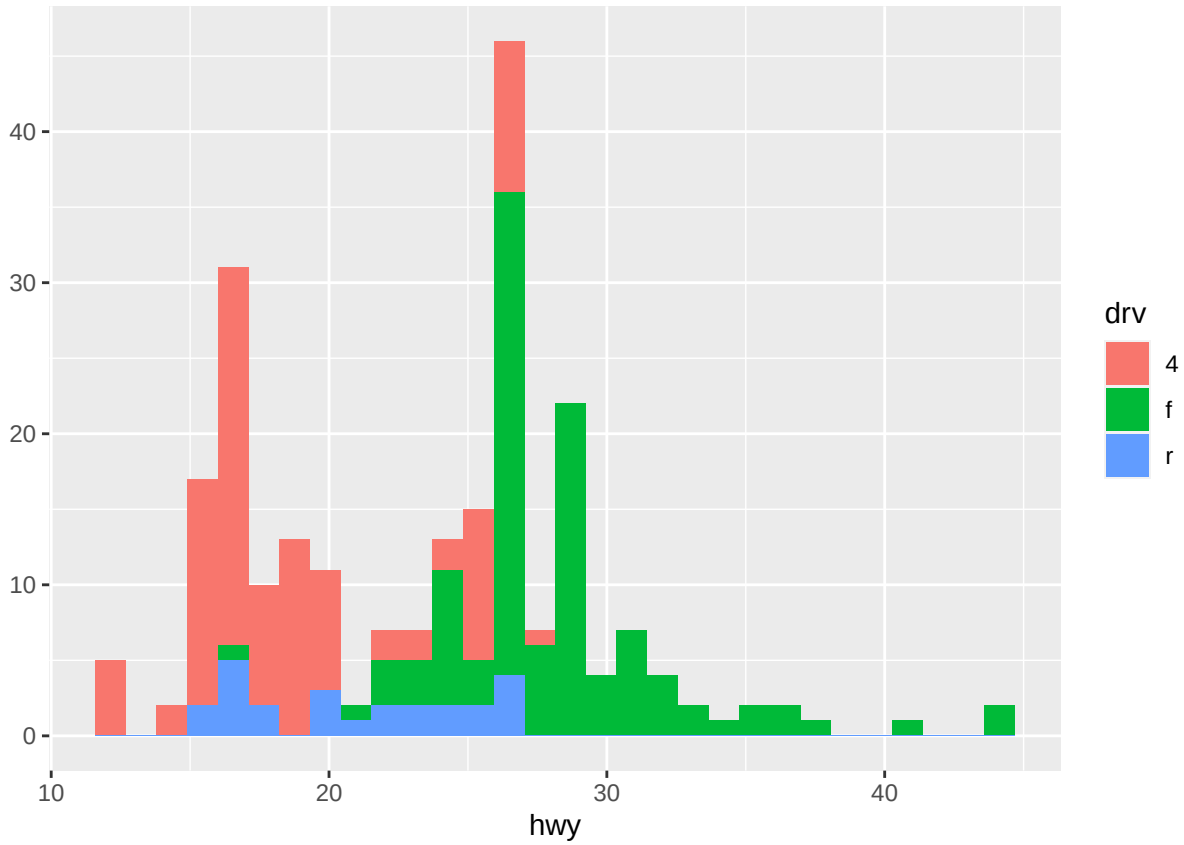

Pentru a reproduce condiționalitatea din sistemul grafic lattice se folosește parametrul facets care primește o formulă ca valoare, dar care coneptual este diferită de cea din sistemul lattice. În cazul de față ce se află la stânga caracterului "~" reprezintă variabila pentru care se vor grupa datele pe rânduri, iar ce se află la dreapta variabila pentru care se vor grupa datele pe coloană. Caracterul "." însemnă că nu dorim o grupare pe coloană sau rând.

```
qplot(Value, data = RoData2019_PM_2_5, facets = . ~ ID)
```

```
## `stat_bin()` using `bins = 30`. Pick better value with `binwidth`.
```

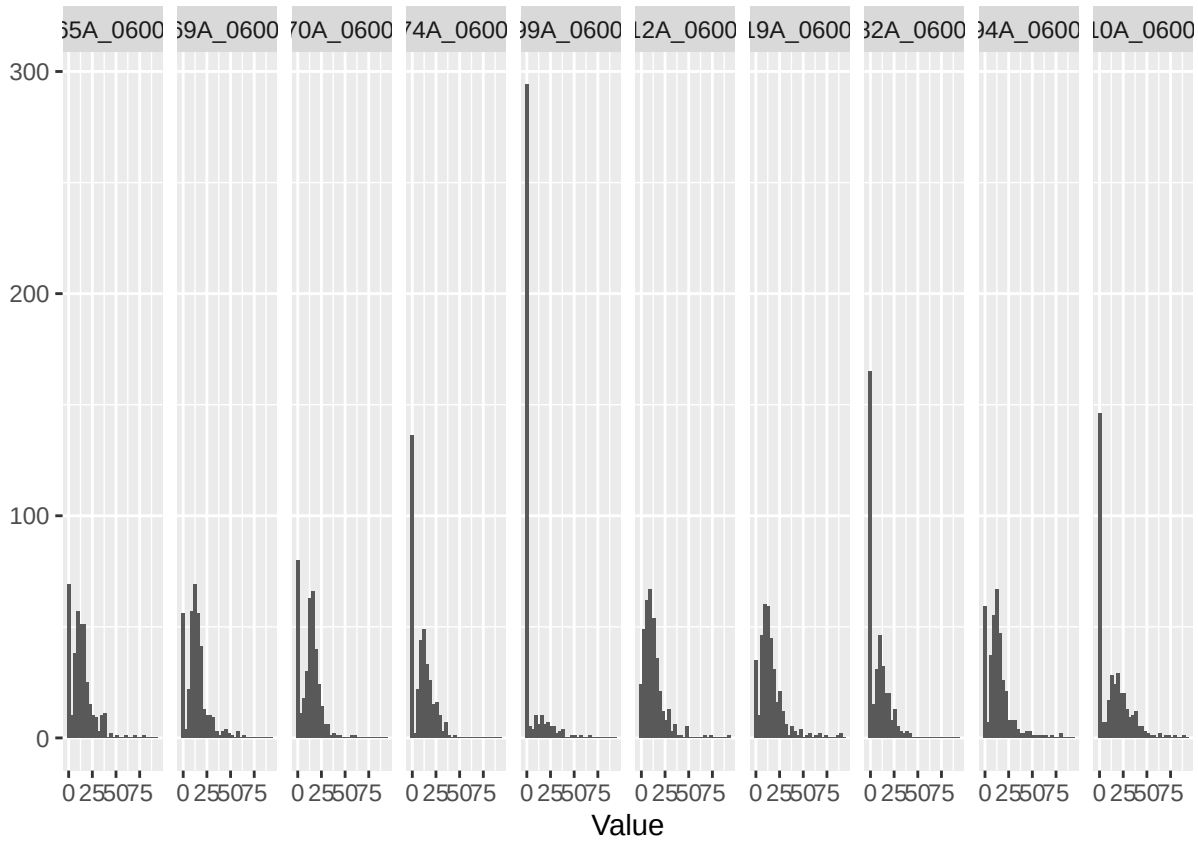


```
qplot(displ, hwy, data = mpg, facets = . ~ drv)
```

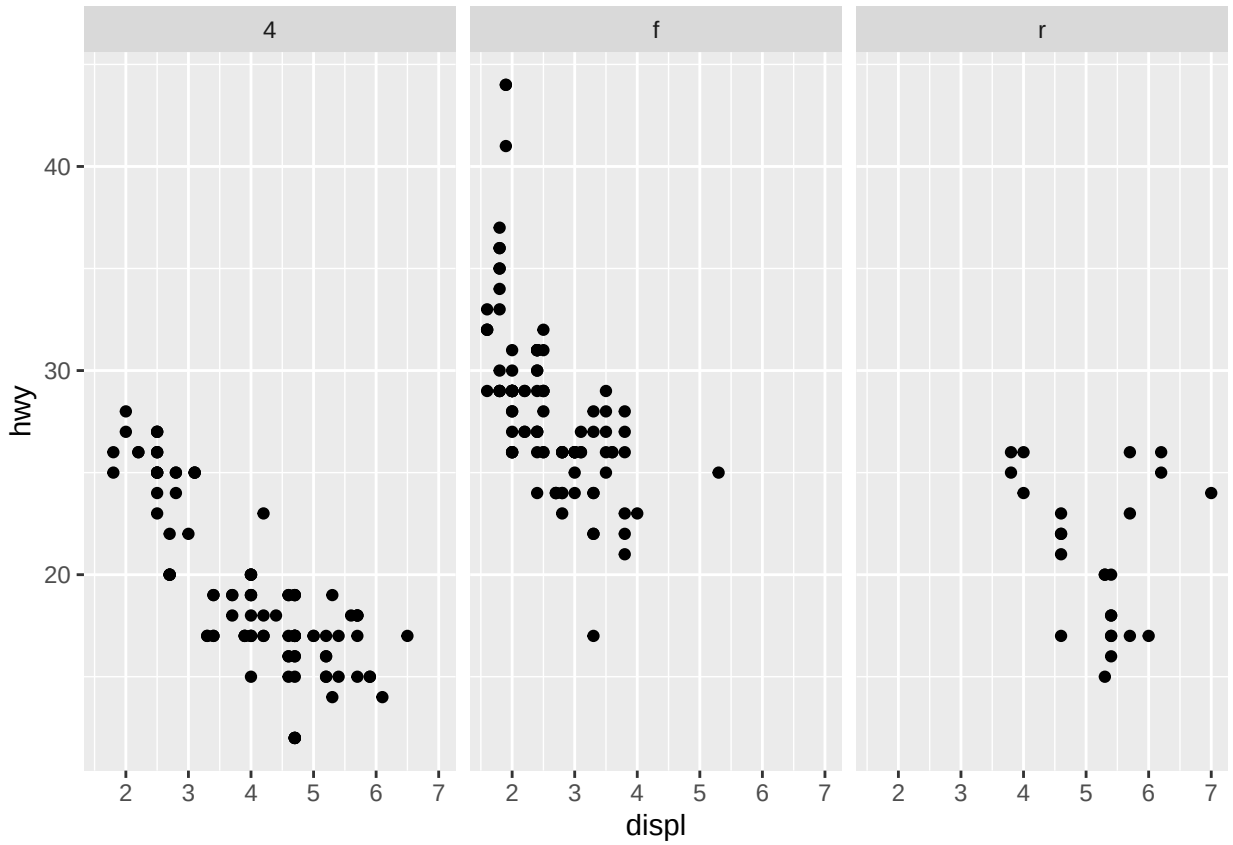


```
qplot(hwy, data = mpg, facets = drv ~ ., binwidth = 2)
```

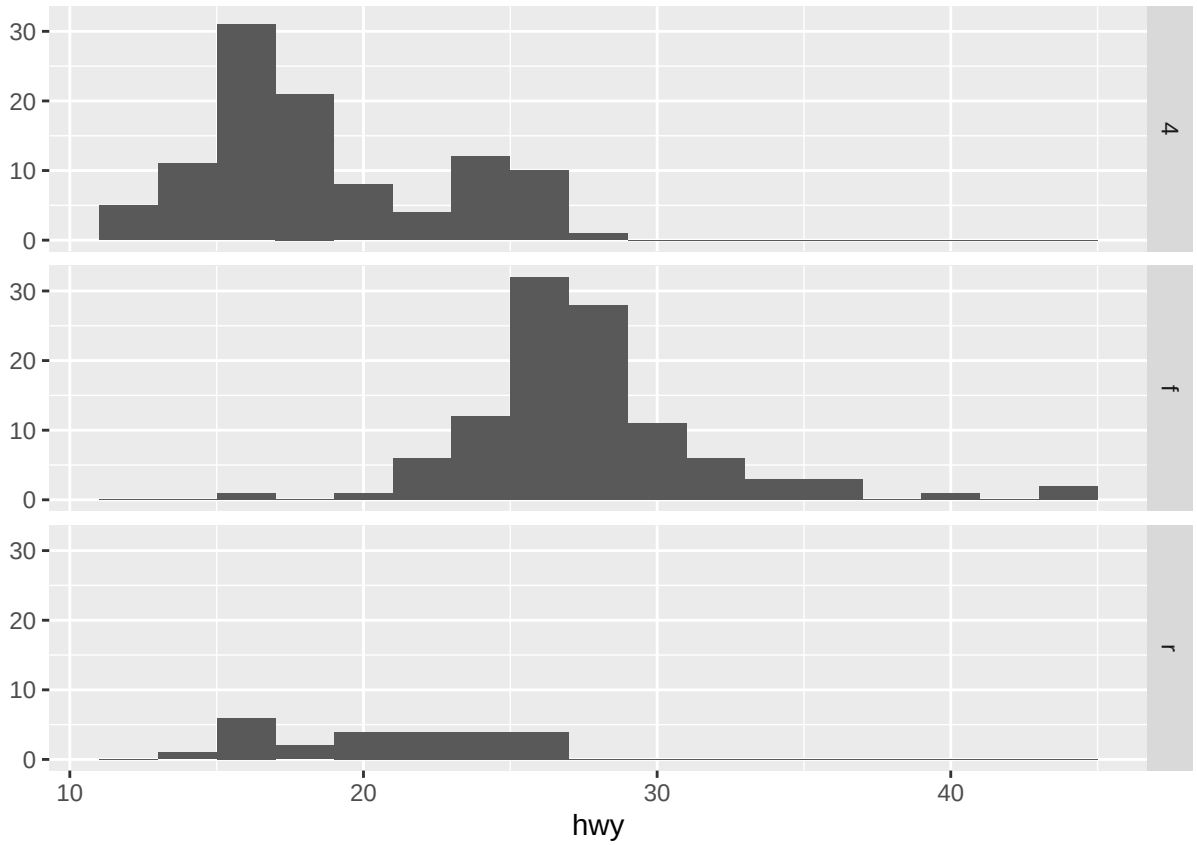

În mod implicit pentru o singură variabilă se vor folosi histograme, iar pentru două variabile se vor folosi puncte. Putem schimba această funcționalitate suprascriind cu ajutorul parmetrului geom.

```
qplot(hwy, data = mpg, facets = drv ~ ., geom = "density")
```

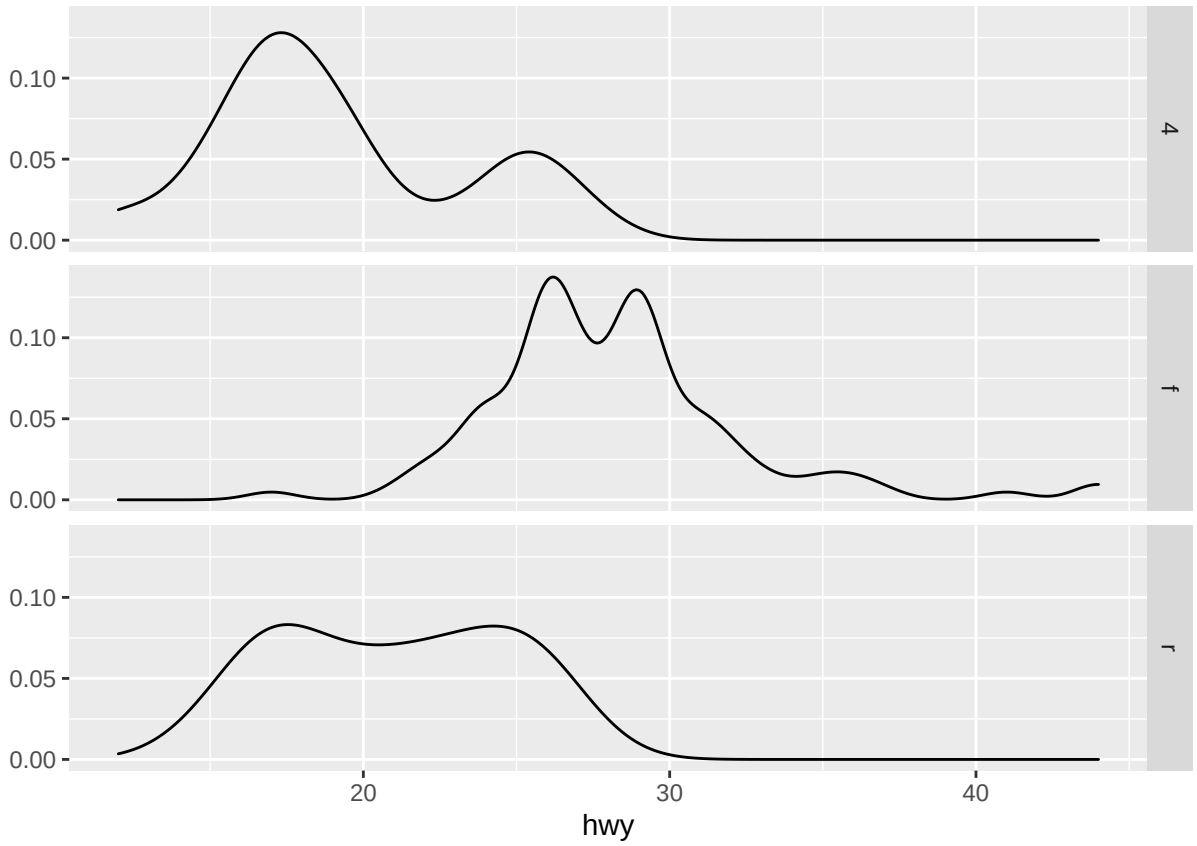


```
qplot(displ, hwy, data = mpg, color = drv, geom = "smooth")
```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

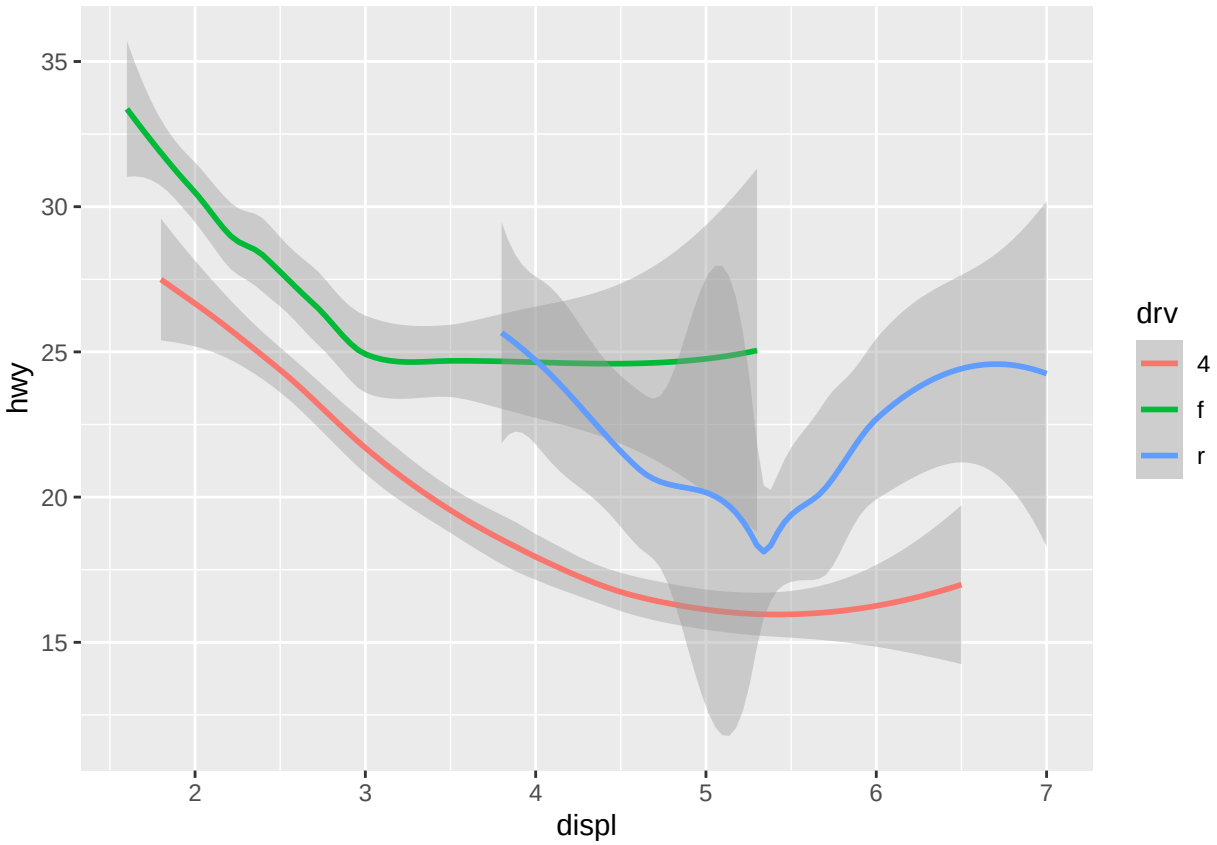

ggplot Funcția ggplot inițializează un obiect cu datele date ca argument și opțional putem adăuga atribute precum valoriile pe axe, dimensiunea, culoarea sau grupări de date.

```
grafic_ro_pm_2_5 <- ggplot(RoData2019_PM_2_5, aes(x = StartDate,
    y = Value))
```

Pentru afișare trebuie să folosim un geom grafic.

```
grafic_ro_pm_2_5 + geom_point()
```

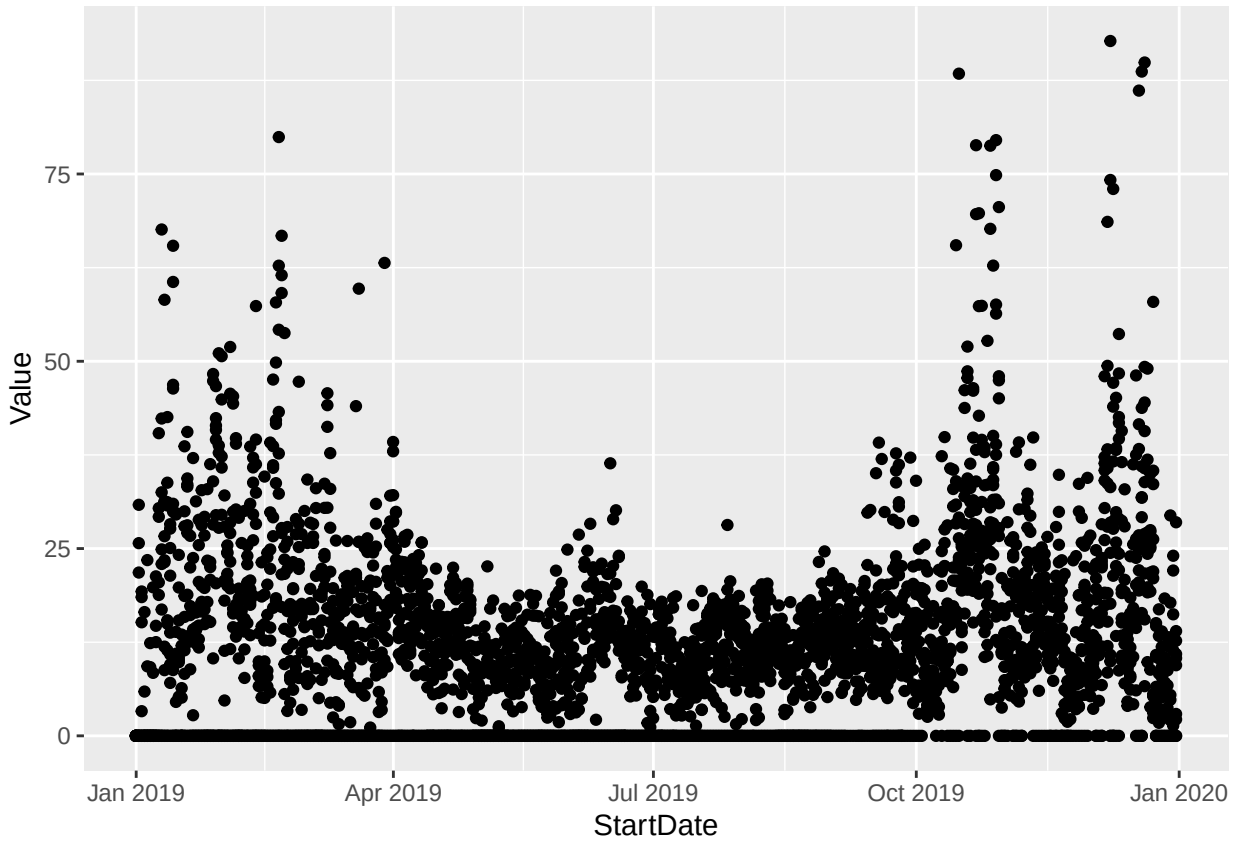

Putem adăuga mai multe funcții geom și putem reține statusul curent al graficului.

```
grafic_ro_pm_2_5_points <- grafic_ro_pm_2_5 + geom_point()
grafic_ro_pm_2_5_points + geom_smooth(method = "lm")
```

```
## `geom_smooth()` using formula 'y ~ x'
```

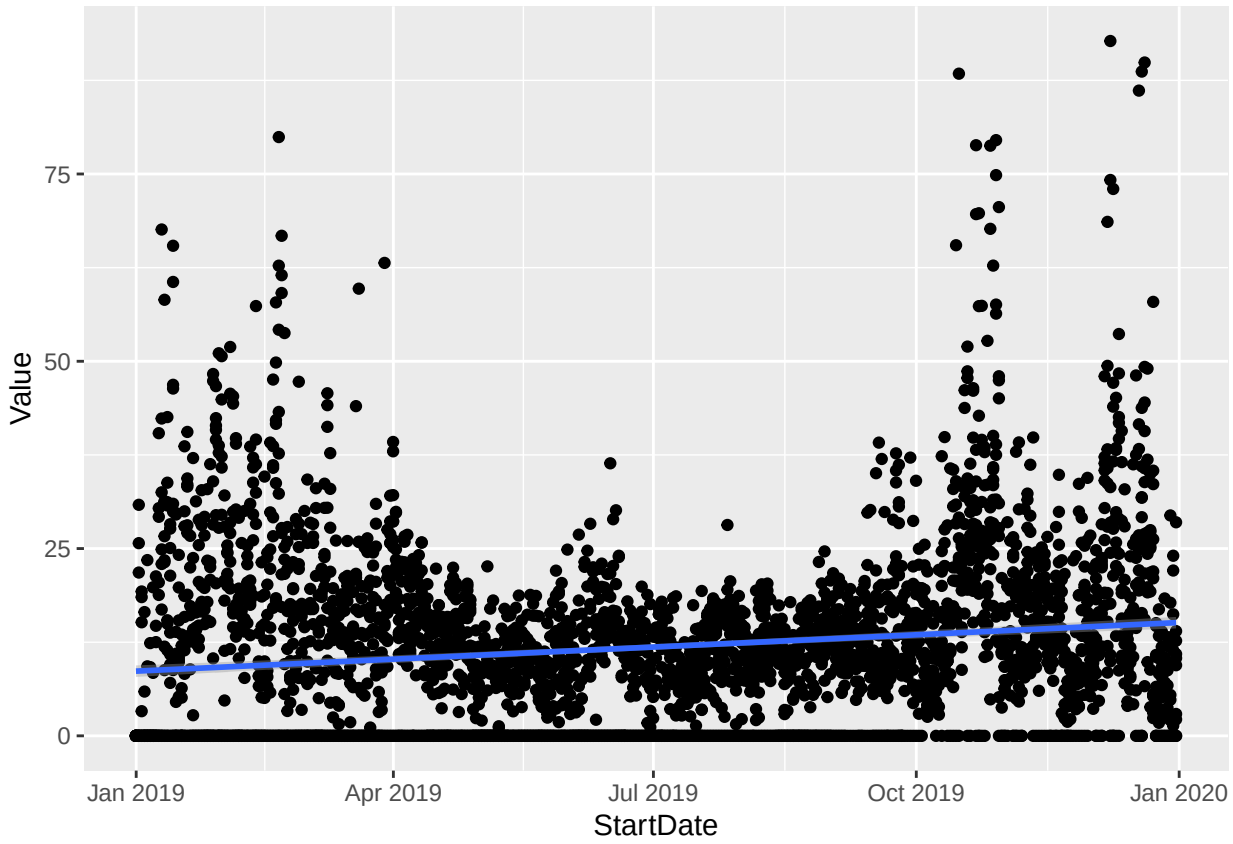

Putem grupa datele cu facet_grid folosind același tip de formule ca la qplot.

```
grafic_ro_pm_2_5_points + facet_grid(. ~ ID) + geom_smooth(method = "lm")
```

```
## `geom_smooth()` using formula 'y ~ x'
```

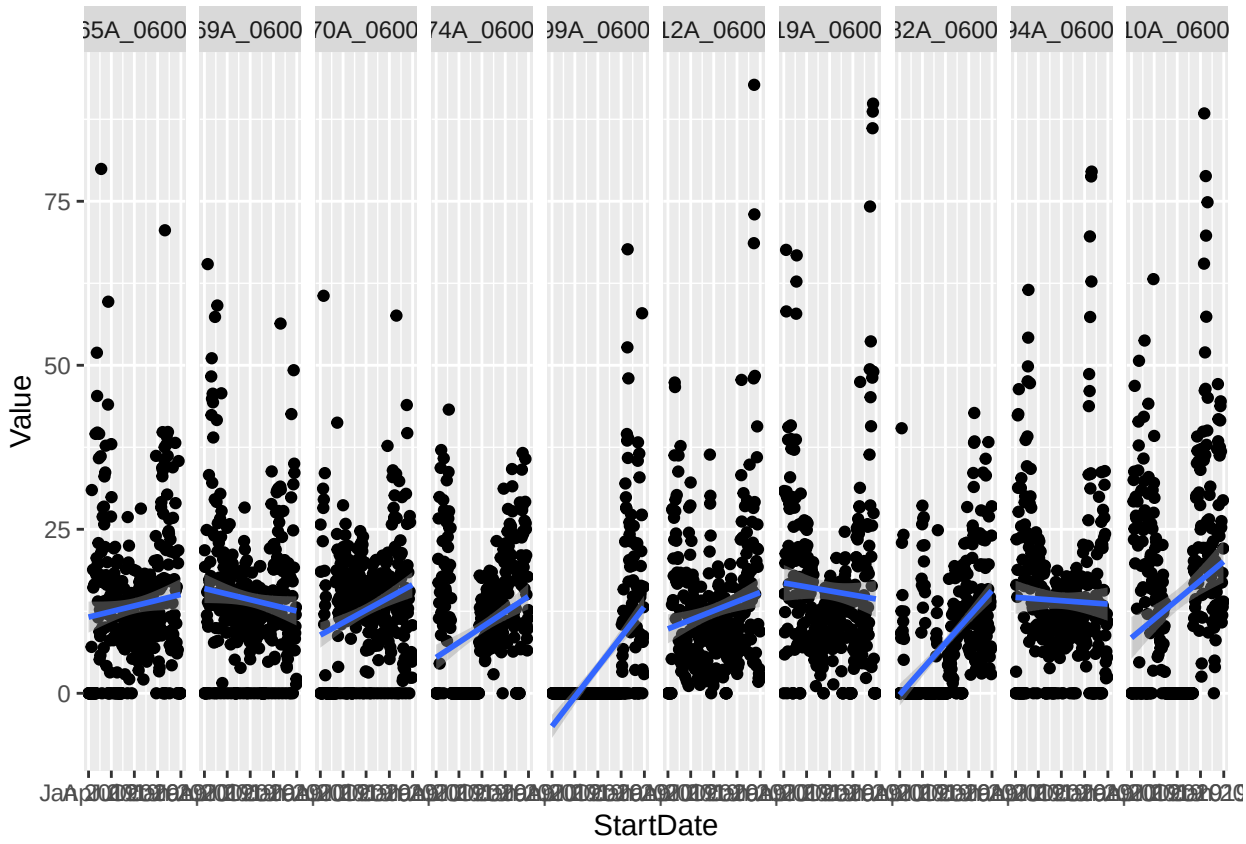

Sunt 2 tipuri de parametri care pot fi dați funcților prin funcția aes sau direct. Cele date cu aes sunt legate strâns de date. Celalte sunt constante globale care afectează obiectele grafice.

```
grafic_ro_pm_2_5 + geom_point(color = "steelblue", alpha = 1/2,
    size = 4)
```

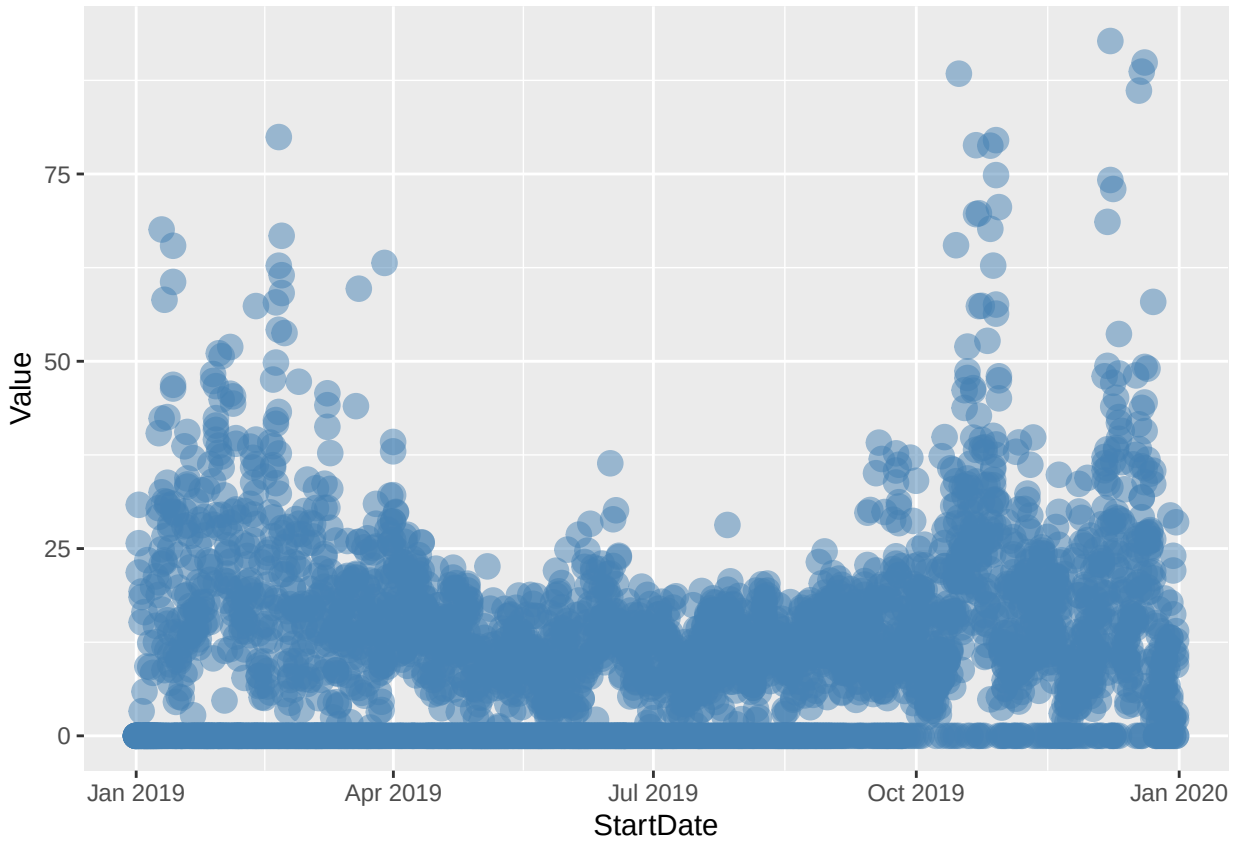


```
grafic_ro_pm_2_5 + geom_point(aes(color = "steelblue"), alpha = 1/2,
    size = 4)
```

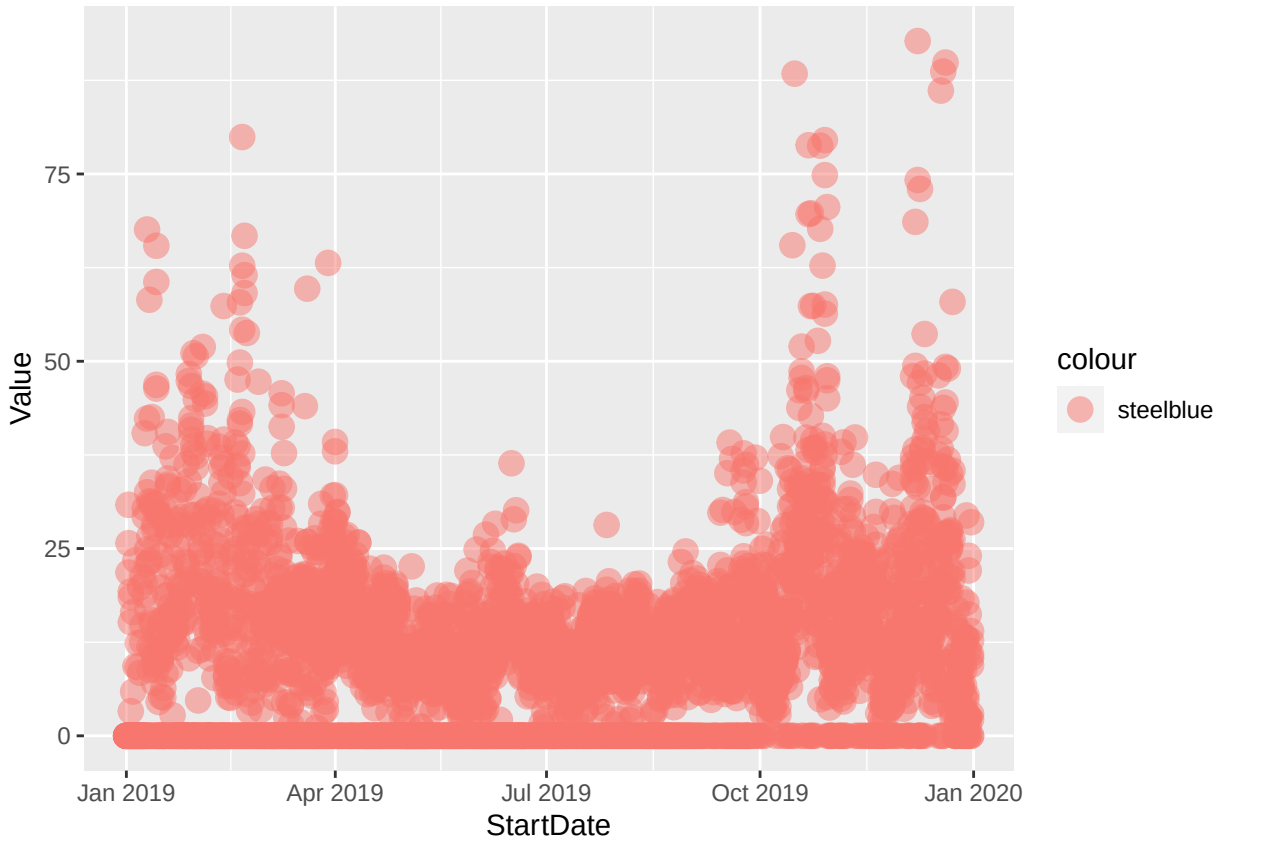


```
grafic_ro_pm_2_5 + geom_point(aes(color = ID), alpha = 1/2, size = 4)
```

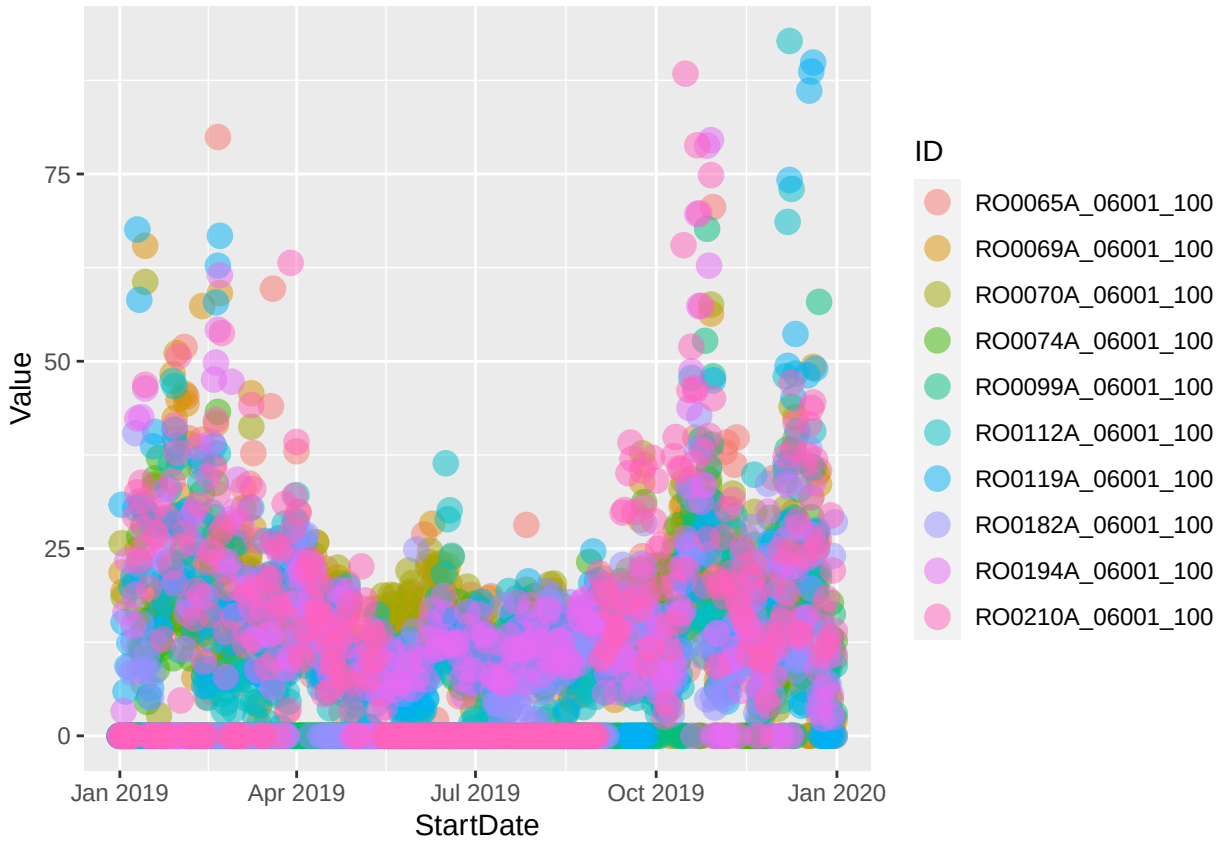

Trecem la ultima compenentă ggplot sistemul de coordoante. Putem adăuga titluri, denumiri pentru axe, legende, schimba fontul, paleta de culori, culorea de fundal, limitele.

```
grafic_ro_pm_2_5 + geom_point(aes(color = ID), alpha = 1/2, size = 4) +
    labs(x = "Data", y = "PM_2_5", title = "Poluant PM_2_5 în Ro") +
    theme(legend.position = "none")
```

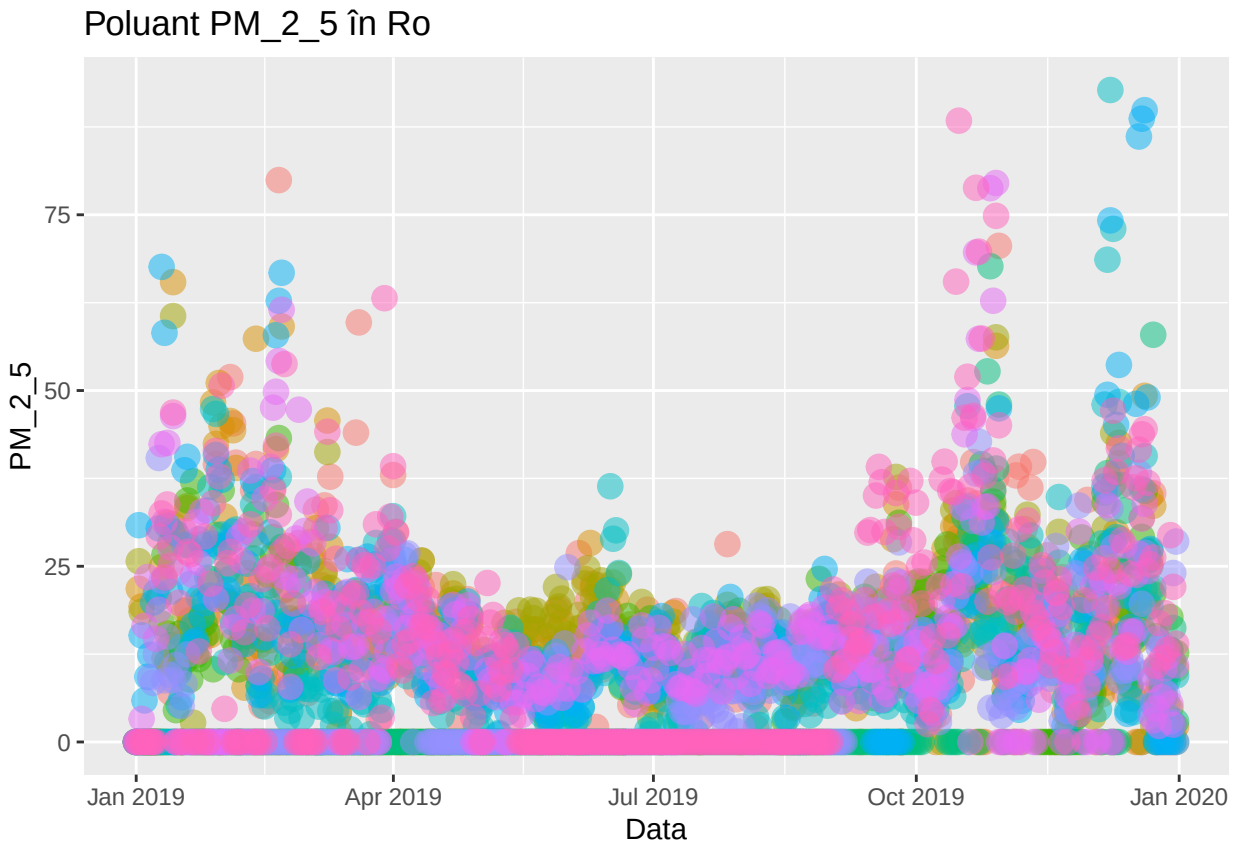


```
grafic_ro_pm_2_5 + geom_point(aes(color = ID), alpha = 1/2, size = 4) +
    labs(x = "Data", y = "PM_2_5", title = "Poluant PM_2_5 în Ro") +
    theme_bw(base_family = "Times")
```

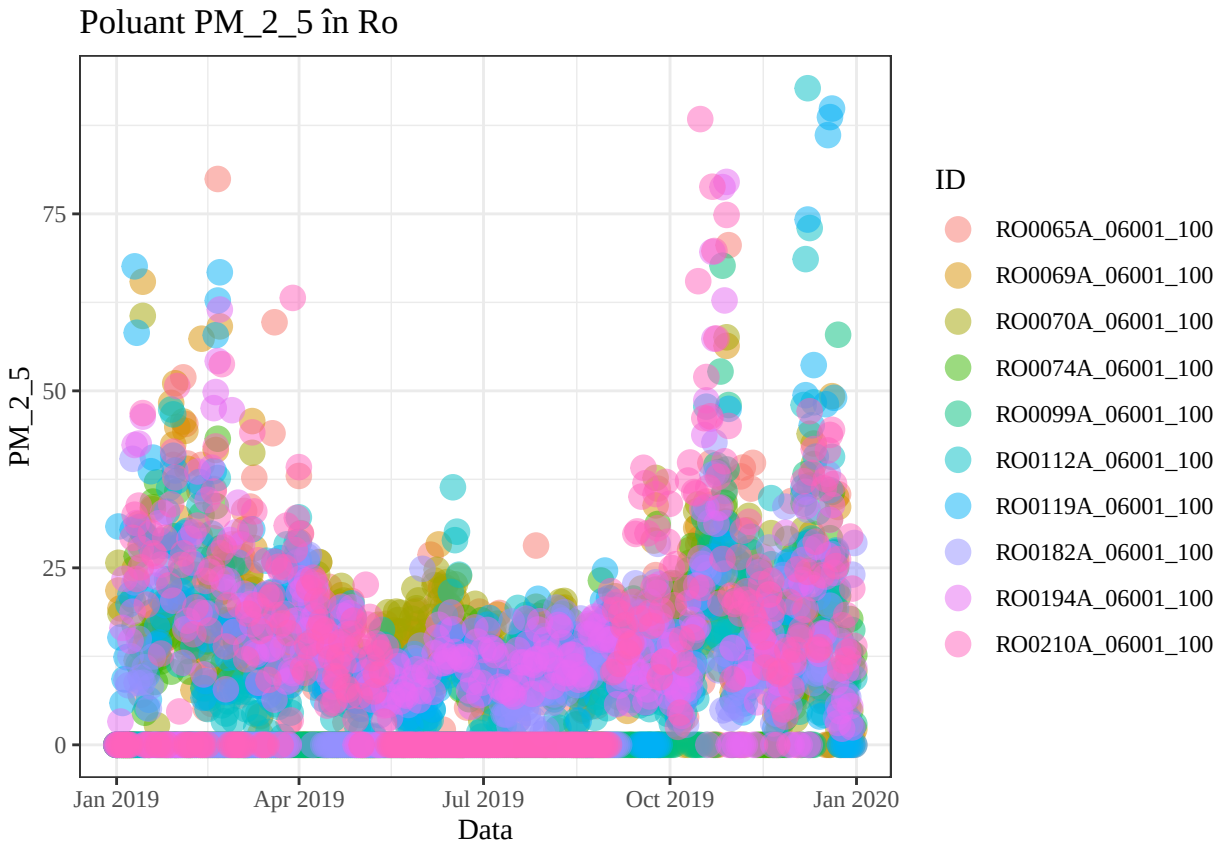


```
grafic_ro_pm_2_5 + geom_point(aes(color = ID), alpha = 1/2, size = 4) +
    labs(x = "Data", y = "PM_2_5", title = "Poluant PM_2_5 în Ro") +
    theme_bw(base_family = "Times") + coord_cartesian(ylim = c(25,
    100))
```

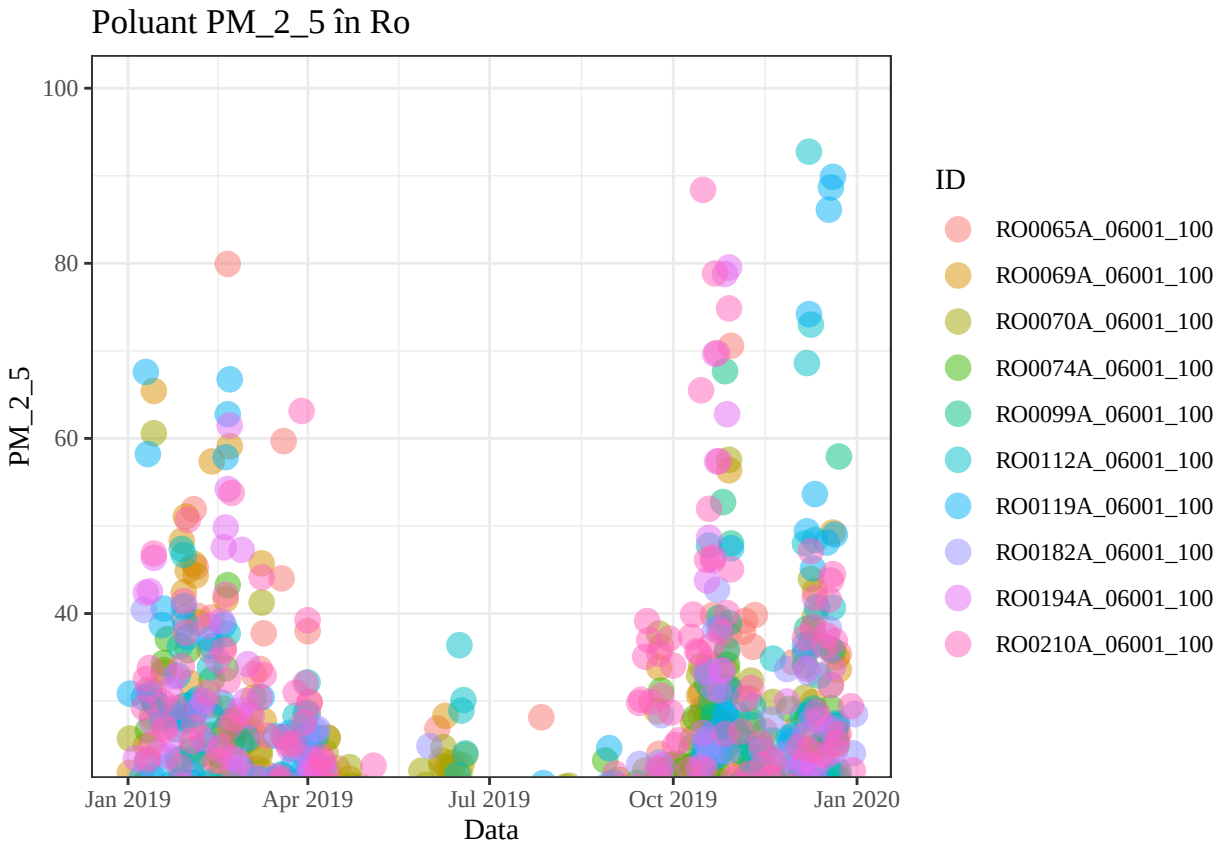

Palete de culori Legat de componenta scale a ggplot2 aceasta aduce funcționalitatea schimbării paletei de culori. Paleta implicită R poate fi derutantă în majoritatea situațiilor. În funcție de scopul graficului putem avea 3 tipuri de palete: - Secvențială. Pentru date continue care sunt ordonate. - Catitativă/Categorică. Când avem date discotinue și categorice. - Divergentă/. Când dorim să arătăm deviația față de un punct.

Bibloteca RColorBrewer ne oferă mai multe palete în aceste 3 categorii. Le putem observa cu funcția display.brewer.all().

Palete secvențiale:

```
display.brewer.all(type = "seq")
```

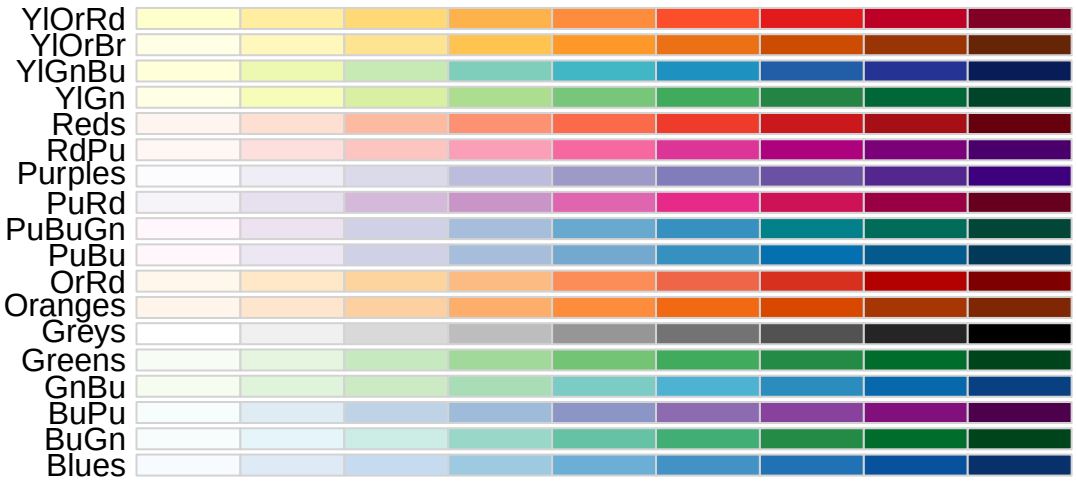

Palete categorice:

```
display.brewer.all(type = "qual")
```

Palete diver-gente:

```
display.brewer.all(type = "div")
```

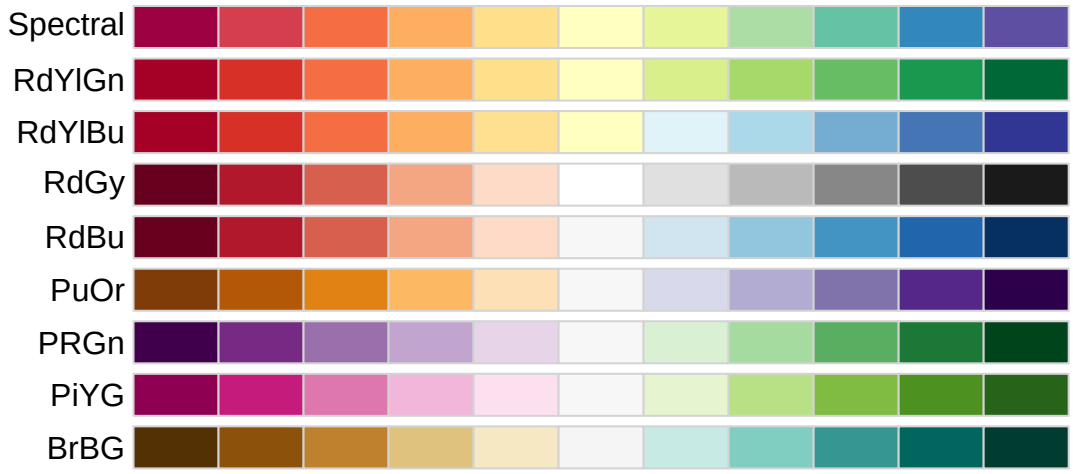

În funcție de yipul de grafic pe care îl avem putem alege paleată pentru colorarea punctelor sau liniilor folosinf funcția scale_color_brewer(palette="X") sau pentru umplerea compentelor în cazul histogramelor, boxplot-urilor folosinf scale_fill_brewer(palette="X").

```
ggplot(roPM_2_5, aes(x = StartDate, y = Value)) + geom_point(aes(color = ID),
    alpha = 1/2, size = 4) + labs(x = "Data", y = "PM_2_5", title = "Poluant PM_2_5 în Ro") +
    theme_bw(base_family = "Times") + coord_cartesian(ylim = c(25,
    100)) + scale_color_brewer(palette = "Set3")
```

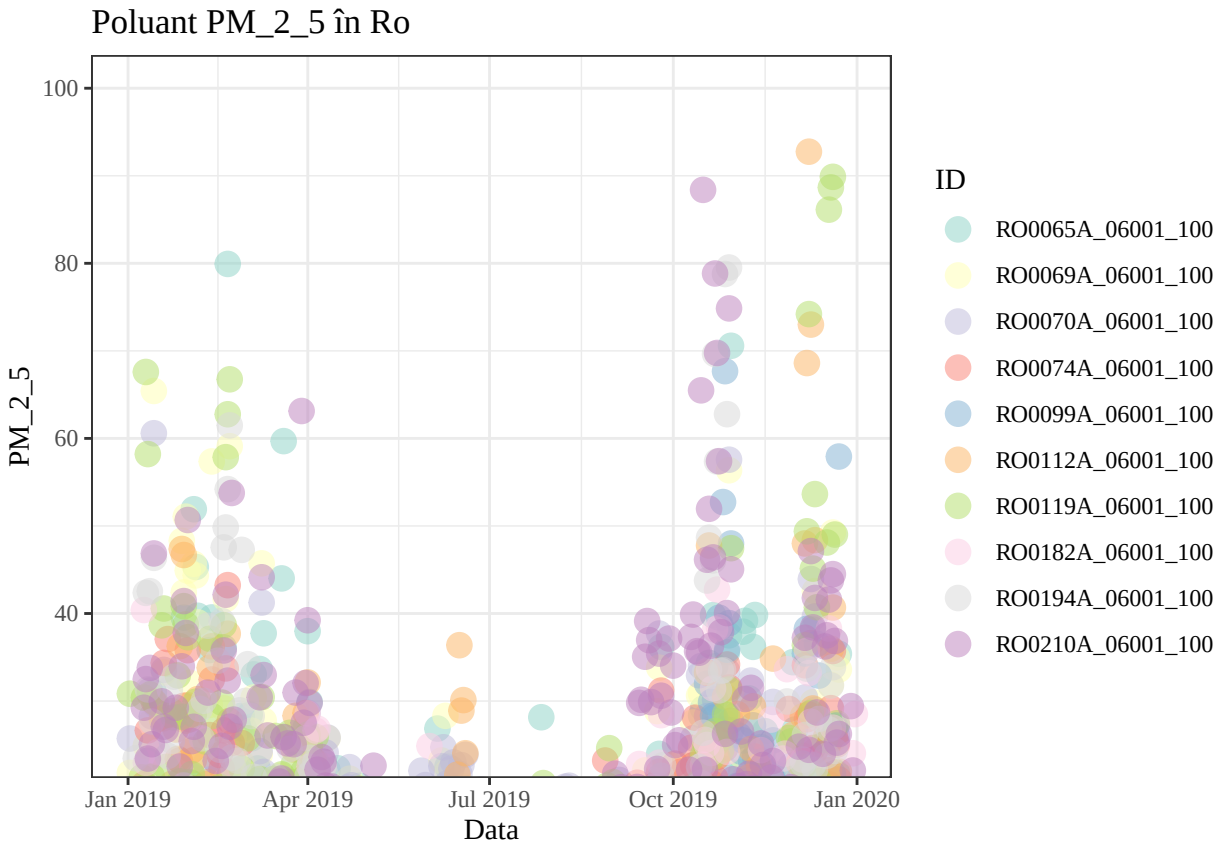


```
ggplot(roPM_2_5, aes(x = Value, group = ID)) + geom_histogram(aes(fill = ID)) +
    labs(title = "Poluant PM_2_5 în Ro") + scale_fill_brewer(palette = "Set3")
```

```
## `stat_bin()` using `bins = 30`. Pick better value with `binwidth`.
```

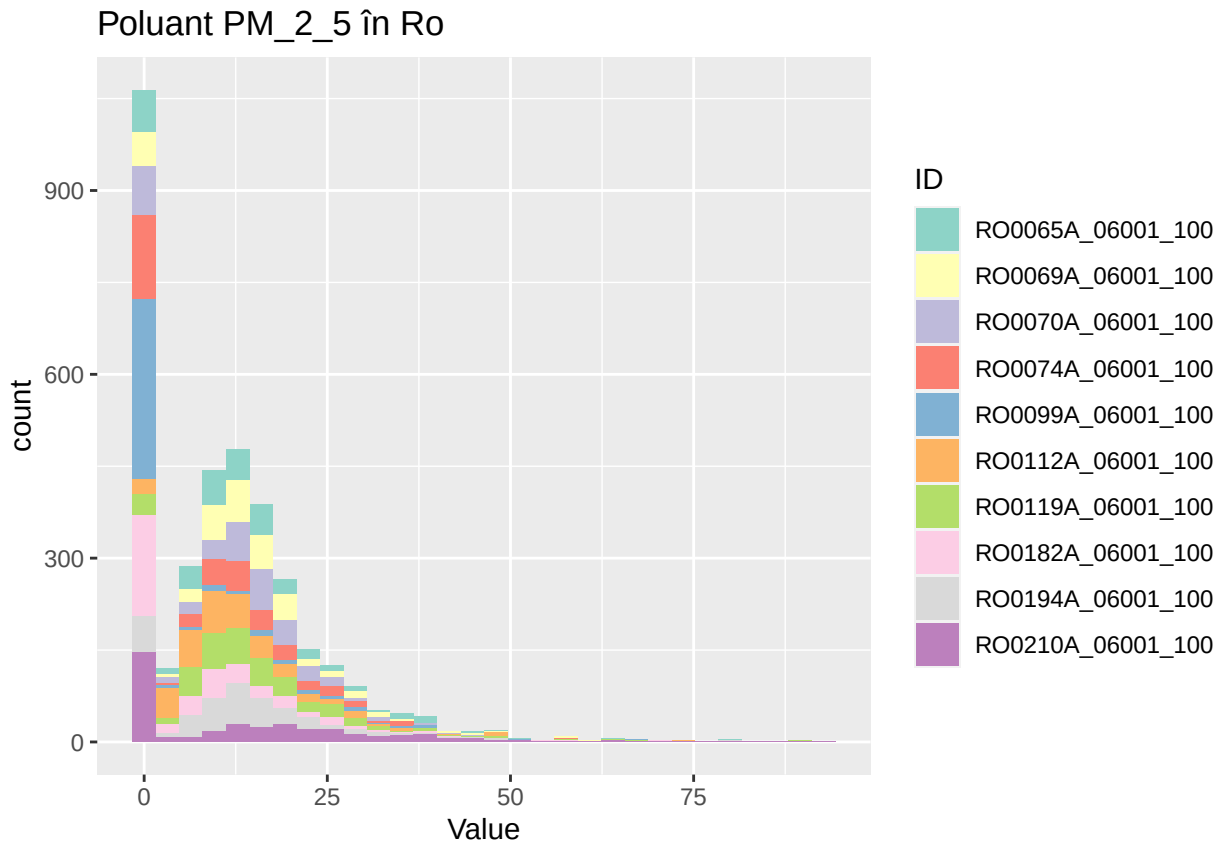


```
ggplot(roPM_2_5, aes(x = StartDate, y = Value)) + geom_point(aes(color = Value)) +
    scale_color_distiller(palette = "RdBu", limits = c(50 - max(abs(roPM_2_5$Value)),
        max(abs(roPM_2_5$Value))))
```

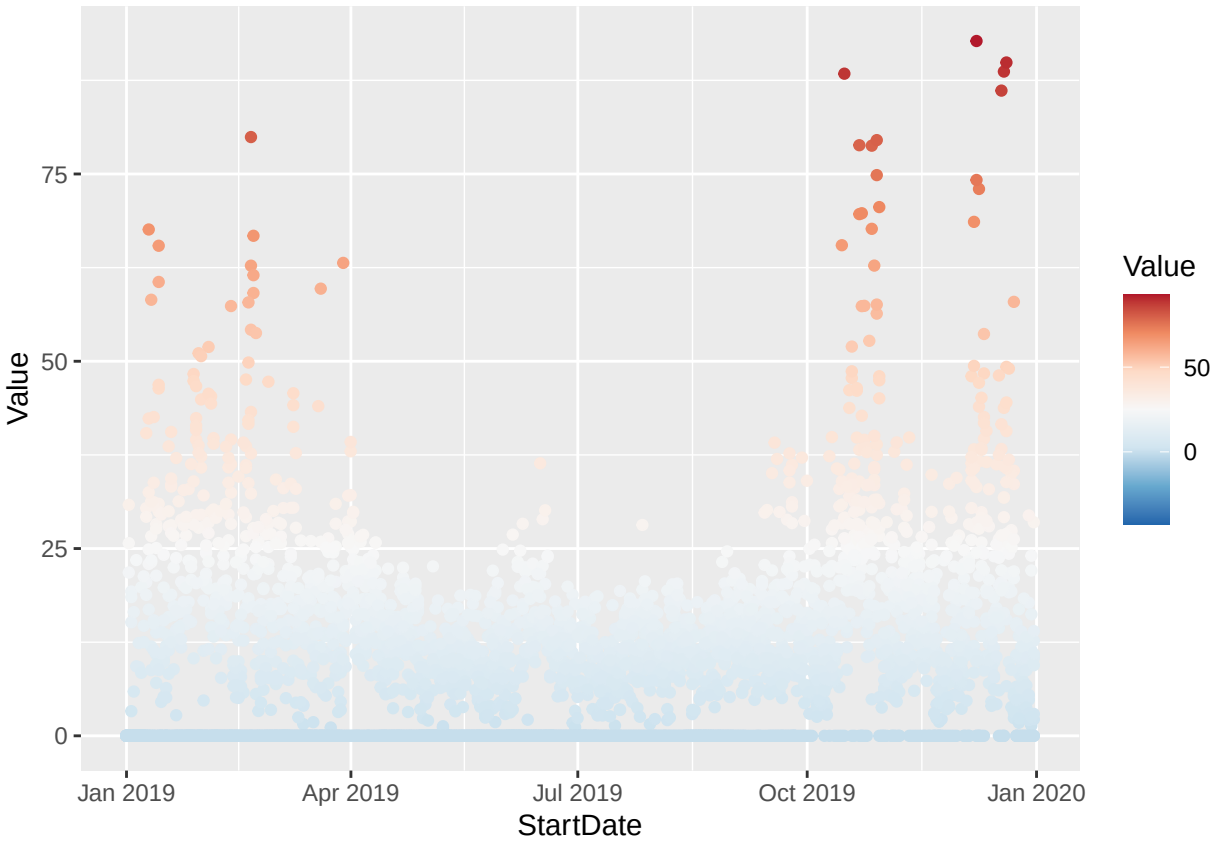

Un alt concept de luat în calcul este vizionarea graficuui în alb-negru cum va apărea în momentul imprimării incolor. Acest lucru se poate face cu ajutor funcțiilor scale_color_grey și scale_fill_grey. Este recomandat să oferim ca parametrul pentru variabila end o valaore mai mică de unu (valoarea implicită) pentru a nu avea puncte albe.

```
ggplot(roPM_2_5, aes(x = Value, group = ID)) + geom_histogram(aes(fill = ID)) +
    labs(title = "Poluant PM_2_5 în Ro") + scale_fill_grey(start = 0.2,
    end = 0.8) + theme_classic()
```

```
## `stat_bin()` using `bins = 30`. Pick better value with `binwidth`.
```

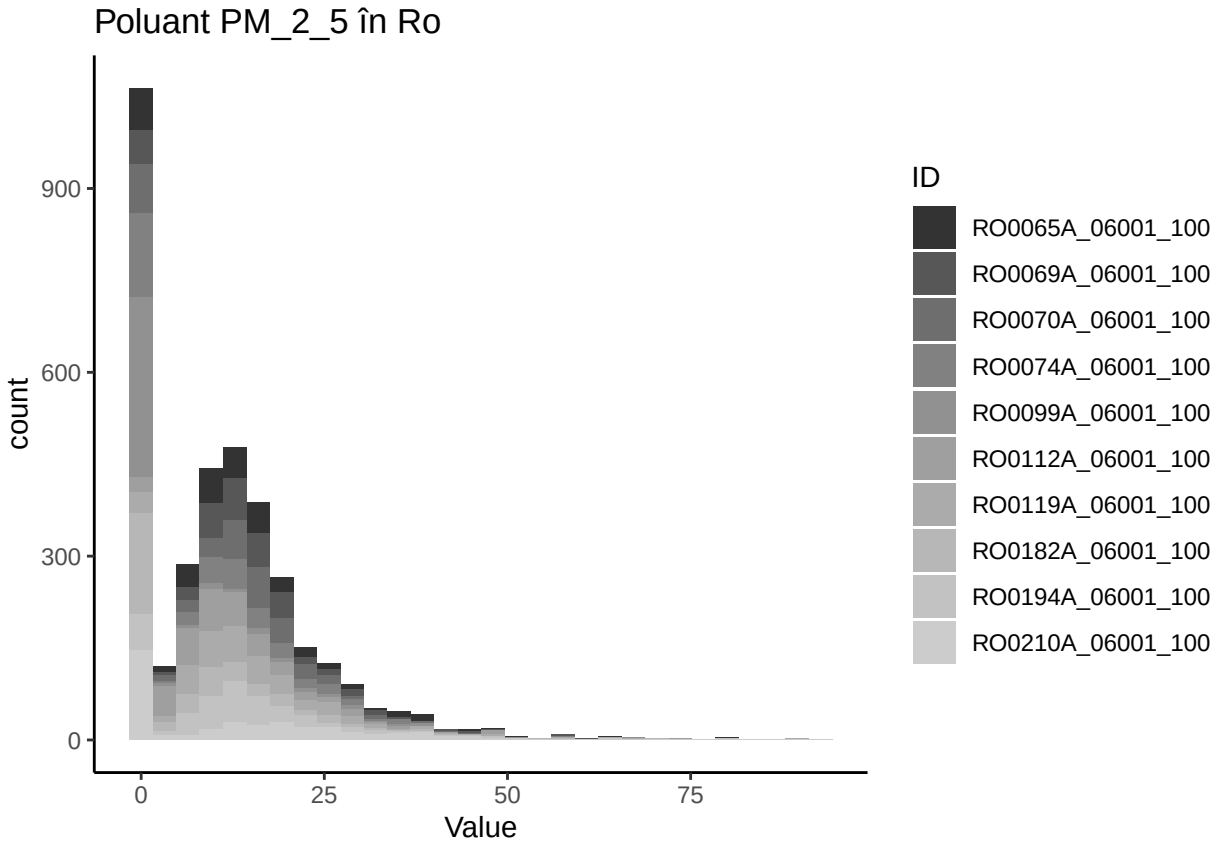

Exerciții

Vom folosi datele despre valoarea poluanților din România în intervalul 2013-2019.

```
RoPollutionFilePath <- file.path("data", "poluare2019.csv")
RoPollutionData2019 <- read.csv(RoPollutionFilePath)
RoPollutionData2019$X <- NULL
colnames(RoPollutionData2019)[1] <- "StartDate"
colnames(RoPollutionData2019)[2] <- "EndDate"
colnames(RoPollutionData2019)[3] <- "Value"
colnames(RoPollutionData2019)[4] <- "Validity"
colnames(RoPollutionData2019)[5] <- "Verfication"
colnames(RoPollutionData2019)[6] <- "ID"
colnames(RoPollutionData2019)[7] <- "PolluantCode"
RoPollutionData2019$StartDate <- ymd_hms(RoPollutionData2019$StartDate)
RoPollutionData2019$ID <- factor(RoPollutionData2019$ID)
RoPollutionData2019$PolluantCode <- factor(RoPollutionData2019$PolluantCode)
RoPollutionData2019$Value <- as.numeric(RoPollutionData2019$Value)
head(RoPollutionData2019)
```

```
##             StartDate             EndDate Value Validity Verfication
## 1 2018-12-31 22:00:00 2018-12-31 23:00:00  0.00        1          -1
## 2 2018-12-31 23:00:00 2019-01-01 00:00:00  7.29        1           1
## 3 2019-01-01 00:00:00 2019-01-01 01:00:00  6.90        1           1
## 4 2019-01-01 01:00:00 2019-01-01 02:00:00  7.02        1           1
## 5 2019-01-01 02:00:00 2019-01-01 03:00:00  7.08        1           1
## 6 2019-01-01 03:00:00 2019-01-01 04:00:00  6.93        1           1
```

```
##                   ID PolluantCode
## 1 RO0066A_00001_100            1
## 2 RO0066A_00001_100            1
## 3 RO0066A_00001_100            1
## 4 RO0066A_00001_100            1
## 5 RO0066A_00001_100            1
## 6 RO0066A_00001_100            1
```

```
roMetadataFilePath <- file.path("data", "rometadata.csv")
roMetadata <- read.csv(roMetadataFilePath, header = TRUE)
head(roMetadata)
```

```
##   X                ID Longitude Latitude Altitude AirQualityStationType
## 1 1 RO0008R_00001_100  25.13484 47.32469      908            background
## 2 2 RO0008R_00005_100  25.13484 47.32469      908            background
## 3 3 RO0008R_00007_100  25.13484 47.32469      908            background
## 4 4 RO0008R_00008_100  25.13484 47.32469      908            background
## 5 5 RO0008R_00009_100  25.13484 47.32469      908            background
## 6 6 RO0008R_00010_100  25.13484 47.32469      908            background
##   AirQualityStationArea AirQualityStationNatCode
## 1          rural-remote                  RO-EM-3
## 2          rural-remote                  RO-EM-3
## 3          rural-remote                  RO-EM-3
## 4          rural-remote                  RO-EM-3
## 5          rural-remote                  RO-EM-3
## 6          rural-remote                  RO-EM-3
```

1

Cum sunt distribuite valoriile pentru dioxid de azot pe anul 2019 ? [http://dd.eionet.europa.eu/vocabulary/aq/pollutant]

2

Care este stația cu cele mai mari valori pentru azot de nitrogen ?

3

Respectă România reccomandările uniunii europene pentru dioxid de azot ? [https://ec.europa.eu/environment/air/quality/standards.htm]

4

Există vreo evoluție a României din anul 2013 la anul 2019 pentru poluantul dioxid de azot ?

5

Există luni în timpul anului 2019 care eu valori ridicate pentru dioxid de azot ?

6

Care este quantila de 90% pentru dioxid de azot pe anul 2019 ?

7

Câte stații de dioxid de azot are România ?

Clustere

Distanta

Merge

Clustere ierarhice

HeatMap

K-means

SVD