

Modelització de dades longitudinals amb efectes aleatoris de intercepció/pendent i presència de dades perdudes en el context dels estudis d'estabilitat – ANNEX 2

Estudiant: Francesc Bernad Martin

M0.178 TFM-Estadística i Bioinformàtica 2

Màster universitari en Bioinformàtica i bioestadística UOC-UB

Àrea: Bioestadística / Bioinformàtica

Nom Consultor/a: Nuria Perez Alvarez

Nom Professor/a responsable de l'assignatura: Carles Ventura Royo

Barcelona, 04 de Juny de 2019



Aquesta obra està subjecta a una llicència de
[Reconeixement-NoComercial-](#)
[SenseObraDerivada 3.0 Espanya](#) de Creative
Commons

Exportació del codi de programació R
Markdown corresponent a la simulació de
models amb dades perdudes

```

---
title: "TFM_ANNEX-2_SIMULACIÓ_DADES_PERDUES"
author: "Francesc Bernad Martín"
date: "May 31, 2019"
output:
  pdf_document:
    toc: yes
    toc_depth: 4
  html_document:
    df_print: paged
    toc: yes
    toc_depth: 4
  word_document:
    toc: yes
    toc_depth: '4'
header-includes:
- \usepackage{float}
- \usepackage{booktabs}
- \usepackage{makecell}
- \usepackage{colortbl}
- \usepackage{xcolor}
---
<style>
body {
text-align: justify}
</style>
```{r, include=FALSE}

options(tinytex.verbose = TRUE)
options(kableExtra.latex.load_packages = FALSE)
```

```{r setup, include=FALSE}
knitr::opts_chunk$set(echo = TRUE, cache =
T,warning=FALSE,message=FALSE)
#Es posa EL CACHE EN TRUE PQ VAGI MÉS RÀPID A GENERAR INFORMES
```

```{r libraries, message=F}
usePackage <- function(p) {
 if (!is.element(p, installed.packages()[,1]))
 install.packages(p, dep = TRUE)
 require(p, character.only = TRUE)
}
usePackage("nlme")
usePackage("nlmeU")
usePackage("lme4")
usePackage("ggplot2")
usePackage("gridExtra")
usePackage("ggExtra")
usePackage("kableExtra")
usePackage("RLRsim")
usePackage("mixlm")
usePackage("magrittr")
usePackage("evaluate")
usePackage("VIM")
usePackage("gridExtra")
usePackage("plyr")
usePackage("dplyr")
usePackage("naniar")
usePackage("mixlm")

```

```

usePackage("mice")

library(bootpredictlme4) # Si no està instal·lat fer servir:
devtools::install_github("remkoduursma/bootpredictlme4")

ctrl <- lmeControl(opt='optim') # Mesura de control per l'aplicació
dels paquets lme per evitar errors per incorrecte optimització
d'iteracions
```

```

Prenent de referència els datasets i models que s'han generat en la simulació corresponent als models mixtos, s'aprofita el codi de programació per fer la simulació de dades perdudes. En aquesta simulació s'eliminaran valors dels mateixos datasets generats de manera aleatòria per simular la pèrdua real de valors en un estudi.

Per reproduir alguns dels resultats de referència prenem la mateixa llavor ja utilitzada en el codi dels models mixtos essent aquesta `7982`.

FUNCIONS DE SIMULACIÓ DE MODELS MIXTOS

Es recuperen algunes de les funcions utilitzades en la simulació de models mixtes per poder veure el comparatiu amb les dades perdudes i es generen algunes de noves (algunes es modifiquen per contemplar la presència de valors perduts):

```

```{r ML I RI funció}
Comp_I_RI_LM <- function(var,ds) {
 fm1 <- formula(paste(var,"~",1,"+", "Error(Lot)"))
 ML_I_RI_SOLS <- summary(ML_I_RI_OLS <- aov(fm1, data = ds))
 ML_I_RI_OLS
 ML_I_RI_OLS_err <- sigma(summary.lm(ML_I_RI_OLS$Within))

 fm2 <- formula(paste(var,"~",1))

 ML_I_RI_SMLE <- summary(ML_I_RI_MLE <- lme(fm2, random = ~1|Lot,
 data = ds, method="ML",na.action=na.omit))

 ML_I_RI_sREML <- summary(ML_I_RI_REML <- lme(fm2,random = ~1|Lot,
 data = ds, method="REML",na.action=na.omit))

 1
 <-
 list(ML_I_RI_OLS$Within,ML_I_RI_SMLE,ML_I_RI_sREML,ML_I_RI_OLS,ML_I_RI
 _MLE,ML_I_RI_REML)
 names(l) <- c("OLS I RI","MLE I RI","REML I RI","OLS I RI
 base","MLE I RI base","REML I RI base"))

 return(l)
}

```

```

```

```{r Resum ML Funció}
ML_Resum <- function(R,Key) {
 ML_table <- data.frame(Sigma = sapply(1:length(R),function(s){
 if (class(R[[s]])[1]=="aov" | class(R[[s]])[1]=="lmm"){
 round(sigma(summary.lm(R[[s]]))),4)
 } else {
 round(sigma(R[[s]]),4)
 }
 }))

```

```

)
ML_table$AIC <- sapply(1:length(R),function(s){
 round(AIC(R[[s]]),4)
})
ML_table$BIC <- sapply(1:length(R),function(s){
 round(BIC(R[[s]]),4)
})
rownames(ML_table) <- paste(Key,names(R),sep="--")

R1 <- ML_table

 ML_table_p <- data.frame(Model =
rep(rownames(ML_table),ncol(ML_table)))
 ML_table_p$Model <- factor(ML_table_p$Model, levels =
rownames(ML_table))
 ML_table_p$ParQ <- unlist(ML_table)
 ML_table_p$Par <- rep(colnames(ML_table),each=nrow(ML_table))

 fact <- if(mean(abs(ML_table$AIC)) >= mean(abs(ML_table$Sigma)))
{ #Es fa un càlcul del factor més adient per graficar les 2 escales en
el gràfic
 10^(round(log10(abs(mean(ML_table$AIC))/abs(mean(ML_table$Sigma))))
)
} else {
 1/(10^(round(log10(abs(mean(ML_table$Sigma))/abs(mean(ML_table$AIC
))))))
}

if (fact==0){
 fact <-0.0001
}

 ML_table_p$ParQ[ML_table_p$Par=="Sigma"] <-
ML_table_p$ParQ[ML_table_p$Par=="Sigma"]*fact

R2 <- ggplot(data=ML_table_p, aes(x=Model, y=ParQ, fill=Par)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Pastel1") + theme_minimal() +
 labs(title=Key,y = "AIC and BIC par.") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Error estàndard res. (Sigma)") +
 theme(text = element_text(size=8),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

 return(list(R1,R2))
}
```
```
```
```
r Resum ML (RSS) Funció Suma Quadrats}
ML_Resum_RSS <- function(R,Key) {
 ML_table <- data.frame(TSS = sapply(1:length(R),function(s){
 round(sum((R[[s]]$residuals)^2),4)
 })
)

 rownames(ML_table) <- paste(Key,names(R),sep="--")

 ML_table_p <- data.frame(Model =
rep(rownames(ML_table),ncol(ML_table)))

```

```

ML_table_p$Model <- factor(ML_table_p$Model, levels =
rownames(ML_table))
ML_table_p$ParQ <- unlist(ML_table)
ML_table_p$Par <- rep(colnames(ML_table),each=nrow(ML_table))

Rp <- ggplot(data=ML_table_p, aes(x=Model, y=ParQ, fill=Par)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Purples") + theme_minimal() +
 labs(title=Key,y = "Suma de quadrats residual (RSS)") +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

 return(Rp)
}

```
```
```{r FuncLists}
#Es genera una funció amb la simple instrucció de quan es facin
llistats dintre llistats converteixi tot en una llista normal sense
subnivells per facilitar els resums
ConvList <- function(List){
  ListC <- list()
  for(l1 in 1:length(List)) {
    if(class(List[[l1]])=="list"){
      for (l2 in 1:length(List[[l1]])) {
        ListC[[length(ListC)+1]] <- List[[l1]][[l2]]
        names(ListC)[length(ListC)] <- names(List[[l1]])[l2]
      }
    } else {
      ListC[[length(ListC)+1]] <- List[[l1]]
      names(ListC)[length(ListC)] <- names(List)[l1]
    }
  }
  return(ListC)
}
```
```
```{r ML_Weights funció,error=TRUE}
Comp_W_LM <- function(fML,fRE,ds,WVI,WVE,WVP) # WVI;WVE;WVP Per
decidir quines funcions s'apliquen essent-> 0:No aplica, 1:Aplicar
MLE, 2:Aplicar REML, 3:Aplicar les 2
{
 baseML <- lme(fML, random = fRE, control=ctrl, data =
ds,method="ML",na.action=na.omit)
 baseREML <- lme(fML, random = fRE, control=ctrl, data =
ds,method="REML",na.action=na.omit)
 l <- list()

 if (paste(fML[3])=="1"){
 fMLk <- "I"
 } else if (paste(fML[3])=="Temps"){
 fMLk <- "IS"
 } else {
 fMLk <- "desconeget"
 }

 if (paste(fRE[2])=="1 | Lot"){
 fREk <- "RI"
 }
}

```

```

} else if (paste(fRE[2])=="1 + Temps | Lot"){
 fREk <- "RIS"
} else if (class(fRE)=="list"){
 fREk <- "DRIS"
} else {
 fREk <- "desconegetu"
}

if(WVI==1 | WVI==3){
 ML_I_RI_WVI_SMLE <- summary(ML_I_RI_WVI_MLE <- update(baseML,
weights = varIdent(form = ~Temps)))
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVI_SMLE
 names(l)[le] <- paste(fMLk, "MLE ", fREk, "VarIdent")
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVI_MLE
 names(l)[le] <- paste(fMLk, "MLE ", fREk, "VarIdent Base")
} else {
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVI_SMLE"
 names(l)[le] <- paste("NE Model", fMLk, "MLE", fREk, "VarIdent")
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVI_MLE"
 names(l)[le] <- paste("NE Model", fMLk, "MLE", fREk, "VarIdent
Base")
}
if(WVI==2 | WVI==3){
 ML_I_RI_WVI_SREML <- summary(ML_I_RI_WVI_REML <-
update(baseREML, weights = varIdent(form = ~Temps)))
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVI_SREML
 names(l)[le] <- paste(fMLk, "REML ", fREk, "VarIdent")
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVI_REML
 names(l)[le] <- paste(fMLk, "REML ", fREk, "VarIdent Base")
} else {
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVI_SREML"
 names(l)[le] <- paste("NE Model", fMLk, "REML", fREk, "VarIdent")
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVI_REML"
 names(l)[le] <- paste("NE Model", fMLk, "REML", fREk, "VarIdent
Base")
}

if(WVE==1 | WVE==3){
 ML_I_RI_WVE_SMLE <- summary(ML_I_RI_WVE_MLE <- update(baseML,
weights = varExp(form = ~Temps)))
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVE_SMLE
 names(l)[le] <- paste(fMLk, "MLE ", fREk, "VarExp")
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVE_MLE
 names(l)[le] <- paste(fMLk, "MLE ", fREk, "VarExp Base")
} else{
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVE_SMLE"
 names(l)[le] <- paste("NE Model", fMLk, "MLE", fREk, "VarExp")
 le <- length(l)+1

```

```

 l[[le]] <- "Pendent ML_I_RI_WVE_MLE"
 names(l)[le] <- paste("NE Model", fMLk, "MLE", fREk, "VarExp Base")
}
if(WVE==2 | WVE==3){
 ML_I_RI_WVE_SREML <- summary(ML_I_RI_WVE_REML <-
update(baseREML, weights = varExp(form = ~Temps)))
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVE_SREML
 names(l)[le] <- paste(fMLk, "REML ", fREk, "VarExp")
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVE_REML
 names(l)[le] <- paste(fMLk, "REML ", fREk, "VarExp Base")
} else{
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVE_SREML"
 names(l)[le] <- paste("NE Model", fMLk, "REML", fREk, "VarExp")
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVE_REML"
 names(l)[le] <- paste("NE Model", fMLk, "REML", fREk, "VarExp Base")
}

#La funció varPower s'ha hagut de deixar sense formules ja que al
fer-la dependre de la covariabile temps no convergia a un resultat real
en els algoritmes de nlme pels conjunts donats

if(WVP==1 | WVP==3){
 ML_I_RI_WVP_SMLE <- summary(ML_I_RI_WVP_MLE <- update(baseML,
weights = varPower()))
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVP_SMLE
 names(l)[le] <- paste(fMLk, "MLE ", fREk, "VarPower")
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVP_MLE
 names(l)[le] <- paste(fMLk, "MLE ", fREk, "VarPower Base")
} else{
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVP_SMLE"
 names(l)[le] <- paste("NE Model", fMLk, "MLE", fREk, "VarPower")
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVP_MLE"
 names(l)[le] <- paste("NE Model", fMLk, "MLE", fREk, "VarPower
Base")
}
if(WVP==2 | WVP==3){
 ML_I_RI_WVP_SREML <- summary(ML_I_RI_WVP_REML <-
update(baseREML, weights = varPower()))
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVP_SREML
 names(l)[le] <- paste(fMLk, "REML ", fREk, "VarPower")
 le <- length(l)+1
 l[[le]] <- ML_I_RI_WVP_REML
 names(l)[le] <- paste(fMLk, "REML ", fREk, "VarPower Base")
} else{
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVP_SREML"
 names(l)[le] <- paste("NE Model", fMLk, "REML", fREk, "VarPower")
 le <- length(l)+1
 l[[le]] <- "Pendent ML_I_RI_WVP_REML"
 names(l)[le] <- paste("NE Model", fMLk, "REML", fREk, "VarPower
Base")
}

```

```

 }

 return(1)
} ..

RECUPERACIÓ DATASETS GENERATS (Ho, He i So)

GENERACIÓ DATASET BASE MIG

Es torna a generar el dataset amb paràmetres de lots/temps mitjos:

```{r Average DS}
set.seed(7982)
i3 <- 3
i10 <- 10

j4 <- 4
j10 <- 10

av_i <- round(mean(c(3,10)))
av_j <- round(mean(c(4,10)))
TA <- c(0,3,6,9,12,18,24,30,36,42) # Es genera un vector amb els temps
més habituals d'estabilitat del qual es prenen els valors segons la
longitud del dataset a utilitzar (es tindrà en compte en el mateix
ordre que està posada encara que es podria contemplar agafant valors
de manera equilibrada entre el principi i el final)
TA_av <- TA[1:av_j]
Av_DS <- data.frame(Lot = rep(paste("Lot",seq(1:av_i)),each=av_j))
Av_DS$NTemps <- as.factor(rep(paste("Temps",seq(1:av_j)),av_i))
Av_DS$Temps <- rep(TA[1:av_j],av_i)
```

GENERACIÓ DATASETS Ho

```{r Ho Dataset}
set.seed(7982)
Av_DS$Ho1 <- runif(n=av_i*av_j, min=-1, max=1) #Observacions constant
de rang petit entre -1 i 1 per simular que no hi ha tendències ni
diferències

set.seed(7982)
Av_DS$Ho2 <- as.vector(sapply(1:av_i, function(i){
  m_lot <- runif(1, min=-1, max=1)
  runif(n=av_j, min=m_lot-0.1, max=m_lot+0.1)
}))
```

GENERACIÓ DATASETS He

```{r He Dataset}
set.seed(7982)
Av_DS$He1 <- as.vector(sapply(1:av_i, function(i){
  m_lot <- runif(1, min=-10, max=10)
  sapply(1:av_j, function(j){
    runif(n=1, min=m_lot-(j*2), max=m_lot+(j*2))
  })
}))
```

set.seed(7982)
Av_DS$He2 <- as.vector(sapply(1:av_i, function(i){

```

```

m_lot <- runif(1, min=-10, max=10)
sapply(1:av_j, function(j){
 runif(n=1, min=m_lot-(j^2), max=m_lot+(j^2))
})
}))

set.seed(7982)
Av_DS$He3 <- as.vector(sapply(1:av_i, function(i){
 m_lot <- runif(1, min=-10, max=10)
 sapply(1:av_j, function(j){
 runif(n=1, min=m_lot-(exp(j)), max=m_lot+(exp(j)))
 })
}))
```

```

```

### GENERACIÓ DATASETS So

```{r So Dataset}
set.seed(7982)
Av_DS$So1 <- as.vector(sapply(1:av_i, function(i){
 sapply(1:av_j, function(j){
 runif(n=1, min=(TA[length(TA)]-TA[j])-1, max=(TA[length(TA)]-
 TA[j])+1) #Observacions constant de rang petit entre -1 i 1 per
 simular que no hi ha tendències ni diferències
 })
}))
```

```

set.seed(7982)
Av_DS$So2 <- as.vector(sapply(1:av_i, function(i){
 m_lot <- runif(1, min=TA[length(TA)]-30, max=TA[length(TA)]+30)
 sapply(1:av_j, function(j){
 runif(n=1, min=(m_lot-TA[j])-1, max=(m_lot-TA[j])+1)
 })
}))
```

```

set.seed(7982)
Av_DS$So3 <- as.vector(sapply(1:av_i, function(i){
 m_lot <- runif(1, min=TA[length(TA)]-10, max=TA[length(TA)]+10)
 s_lot <- runif(1, min=0.1, max=2)
 sapply(1:av_j, function(j){
 runif(n=1, min=(m_lot-(s_lot*TA[j]))-1, max=(m_lot-(s_lot*TA[j]))+
 1)
 })
}))
```

```

```

# GENERACIÓ DATASETS AMB DADES PERDUES
```

Per la generació dels datasets amb dades perdudes es tenen en compte varis nivells segons el % de dades perdudes i en base a cada nivell es generen dos vectors, un a nivell de lots i l'altre de temps d'anàlisi (TA) amb els punts a eliminar. Per fer-ho d'una manera semialeatòria s'utilitza la funció de R `sample_frac` del paquet `dplyr` amb la llavor comentada (generem una funció personalitzada per poder-ho fer més automàtic).

```

```{r Vectors de MD}
MD_list <- function(DS,percmin,percmax,percseq){ #La funció pren la
matriu de dades i genera tantes matrius com es defineixen segons el
rang de percentatge de dades perdudes essent tots els percentatges en
tant per 1, percmin el % mínim, percmax el % max i percseq la
separació de % entre matrius
 perc_rang <- seq(from=percmin,to=percmax,by=percseq)
 MDlist <- lapply(c(0,perc_rang),function(pe){
 set.seed(7982)
 md_vec <- sample(nrow(DS),size=round(nrow(DS)*pe),replace=F)
 DS[md_vec,4:ncol(DS)] <- NA
 DS
 })
 names(MDlist) <- paste(100*c(0,perc_rang),"% VP",sep=" ")
 return(MDlist)
}

perc <- c(0.2,0.6,0.2)
perc_rang0 <- seq(from=perc[1],to=perc[2],by=perc[3])
Av_DS_MD_list <- MD_list(Av_DS,perc[1],perc[2],perc[3])
```

```

VISUALITZACIÓ DATASETS GENERATS

GRÀFICS GENERALS DADES PERDUES

Els següents gràfics mostren les proporcions en general que s'apliquen de dades perdudes als punts sense tenir en compte a quina variable s'aplica. Encara que es vegi aplicat a Ho1 són els mateixos per la resta de variables.

Spinegrams

Veiem els gràfics anomenats spineplots que ajuden a visualitzar els percentatges de dades perdudes i les proporcions dins els factors de la matriu Lot i Temps:

```

```{r Spine plots Ho}
par(mfrow=c(1,length(Av_DS_MD_list)-1))
Av_DS_MD_spm <- lapply(2:length(Av_DS_MD_list),function(p){
 list(spineMiss(Av_DS_MD_list[[p]]
 [,c("Ho1")]),main=names(Av_DS_MD_list)[p]),
 spineMiss(Av_DS_MD_list[[p]]
 [,c("Lot","Ho1")]),main=names(Av_DS_MD_list)[p]),
 spineMiss(Av_DS_MD_list[[p]])
 [,c("NTemps","Ho1")]),main=names(Av_DS_MD_list)[p])
})
```

```

Diagrames de Mosaic

```

```{r Mosaic MD}
Av_DS_MD_mos <- lapply(2:length(Av_DS_MD_list),function(p){
 list(mosaicMiss(Av_DS_MD_list[[p]][,c("Lot","NTemps","Ho1")]),
 highlight = 3,
 plotvars = 1:2, miss.labels =
 FALSE,main=names(Av_DS_MD_list)[p]))
})
```

```

```

### Diagrames de caixa

```{r pbox MD}
par(mfrow=c(1,2))
Av_DS_MD_pbox <- lapply(2:length(Av_DS_MD_list), function(p){
 list(pbox(Av_DS_MD_list[[p]][, c("Lot",
 "Ho1")], main=names(Av_DS_MD_list)[p]),
 pbox(Av_DS_MD_list[[p]][, c("Temps",
 "Ho1")], main=names(Av_DS_MD_list)[p])))
 })
```

### Relació de paràmetres

```{r par coord MD}
par(mfrow=c(length(Av_DS_MD_list)-1,1))
Av_DS_MD_pcor <- lapply(2:length(Av_DS_MD_list), function(p){
 parcoordMiss(Av_DS_MD_list[[p]][, c("Lot", "NTemps", "Temps", "Ho1")],
 highlight = 'Ho1', alpha = 0.6, main=names(Av_DS_MD_list)[p])
})
```

### MatrixPlot

```{r matrixplot MD}
par(mfrow=c(1,length(Av_DS_MD_list)-1))
Av_DS_MD_matp <- lapply(2:length(Av_DS_MD_list), function(p){
 matrixplot(Av_DS_MD_list[[p]][, c("Lot", "NTemps", "Temps", "Ho1")],
 sortby=c('Lot'), main=names(Av_DS_MD_list)[p])
})
```

```

En els diferents gràfics es mostra com s'ha aplicat d'una manera aproximadament igualada les absències de dades. Evidentment com més petita és la mida mostral és més fàcil que es donin diferències i veure possibles patrons que realment amb una mida mostral més gran no hi serien.

GRÀFICS DE DADES PERDUDES ESPECÍFICS PER CONJUNT

```

```{r marginplot MD}
DS_Vars <- c("Ho1", "Ho2", "He1", "He2", "He3", "So1", "So2", "So3")

lapply(DS_Vars, function(V){
 par(mfrow=c(1,length(Av_DS_MD_list)-1))
 Lot_MD_marp <- lapply(2:length(Av_DS_MD_list), function(p){
 marginplot(Av_DS_MD_list[[p]][, c("Lot", V)],
 main=names(Av_DS_MD_list)[p])
 })
 Temps_MD_marp <- lapply(2:length(Av_DS_MD_list), function(p){
 marginplot(Av_DS_MD_list[[p]][, c("NTemps", V)],
 main=names(Av_DS_MD_list)[p])
 })
}

par(mfrow=c(1,1))
```

```

Els gràfics específics per variable ens mostren com canvia la distribució de dades perdudes en front del factor Lot i del factor Temps. Al estar aplicant una simulació de MCAR pur es pot veure que:

- + En els gràfics sense patró lògic al tenir absència de dades segueix aproximadament una distribució similar, excepte potser algun cas del % més alt de dades perdudes.
- + En els gràfics que segueixen un patró també aparentment es manté la tendència tot i perdre observacions.

En general es veu que per MCAR fins i tot agafant pèrdues de dades de fins al `r perc[2]*100` % no s'observen casos molt preocupants a nivell visual (una altra cosa és a nivell de càlcul que es veu més endavant).

```
```{r Complet Scatterplots}
labs_1 <- matrix(paste(rep(DS_Vars,each=length(Av_DS_MD_list)),names(Av_DS_MD_li
st),sep=" "),ncol=length(DS_Vars))
labs_2 <- matrix(paste(rep(DS_Vars,each=length(Av_DS_MD_list)),"s/
Lot",names(Av_DS_MD_list),sep=" "),ncol=length(DS_Vars))

Av_DS_MD_plot_sc1 <- lapply(1:length(DS_Vars),function(g){
 lapply(1:length(Av_DS_MD_list),function(p){
 ggplot(Av_DS_MD_list[[p]], aes(x=Temps, y=Av_DS_MD_list[[p]]
[,paste(DS_Vars[g])])) + geom_point() +
 geom_smooth(linetype="dashed") + labs(title=labs_1[p,g], y =
"Observacions") +
 geom_miss_point()
 })
})

Av_DS_MD_plot_sc2 <- lapply(1:length(DS_Vars),function(g){
 lapply(1:length(Av_DS_MD_list),function(p){
 ggplot(Av_DS_MD_list[[p]], aes(x=Temps, y=Av_DS_MD_list[[p]]
[,paste(DS_Vars[g])], color=Lot, group=Lot)) +
 geom_point() + geom_smooth(method="lm", se=F) +
 labs(title=labs_2[p,g], y = "Observacions") +
 geom_miss_point()
 })
})

Av_DS_MD_ydens_plot <- lapply(1:length(DS_Vars),function(g){
 lapply(1:length(Av_DS_MD_list),function(p){
 ggplot(Av_DS_MD_list[[p]], aes(x=Av_DS_MD_list[[p]]
[,paste(DS_Vars[g])])) +
 geom_density(color="darkblue", fill="lightblue") +
 geom_vline(aes(xintercept=mean(DS_Vars[g])), color="blue",
linetype="dashed", size=1) +
 labs(title=labs_1[p,g], x = "Observacions")
 })
})

lapply(1:length(DS_Vars),function(g){
 grid.arrange(grobs = Av_DS_MD_plot_sc1[[g]])
})

lapply(1:length(DS_Vars),function(g){ #Per aquest gràfic només prenem
 grid.arrange(grobs = Av_DS_MD_plot_sc2[[g]])
})
```

```

lapply(1:length(DS_Vars), function(g){
 grid.arrange(grobs = Av_DS_MD_ydens_plot[[g]])
})

```

Dins la quantitat d'informació generada com a idees generals podria semblar que:

- + Les dades perdudes afectarien menys quan les dades estan realment molt centrades.
- + En els casos de mesures ja disperses potser tampoc tindrien un efecte rellevant al ja seguir disperses.
- + En els casos amb patrons molt marcats, però amb dades més disperses possiblement si que podrien generar patrons diferents que falsejarien les prediccions (per exemple a So<sub>2</sub> o H<sub>2</sub>O).

#### # MODELITZACIÓ AMB DADES PERDUDDES

Es prenen models que hagin donat bons resultats en la modelització de models amb dades mixtes per fer els comparatius dels conjunts generats en aquesta simulació.

#### ## AJUST MODELS I CÀLCUL CONTRAST RLRT

```

```{r MD ML I RI Ho1/Ho2}

Comp_I_RI_MD_Ho1 <- lapply(1:length(Av_DS_MD_list), function(p){
  Comp_I_RI_LM("Ho1",Av_DS_MD_list[[p]])
})

names(Comp_I_RI_MD_Ho1) <- names(Av_DS_MD_list)

fmHo1 <- formula(paste("Ho1","~",1))
Comp_I_RI_MD_Ho1_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_Ho1<-exactRLRT(lme(fmHo1, random = ~1|Lot, data =
Av_DS_MD_list[[p]]], method="REML",na.action=na.omit))
})

names(Comp_I_RI_MD_Ho1_RLRT) <- names(Av_DS_MD_list)

Comp_I_RI_MD_Ho2 <- lapply(1:length(Av_DS_MD_list), function(p){
  Comp_I_RI_LM("Ho2",Av_DS_MD_list[[p]])
})

names(Comp_I_RI_MD_Ho2) <- names(Av_DS_MD_list)

fmHo2 <- formula(paste("Ho2","~",1))
Comp_I_RI_MD_Ho2_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_Ho2<-exactRLRT(lme(fmHo2, random = ~1|Lot, data =
Av_DS_MD_list[[p]]], method="REML",na.action=na.omit))
})

names(Comp_I_RI_MD_Ho2_RLRT) <- names(Av_DS_MD_list)

```

```{r MD ML I RI He}
#Ajustarem per varExp al ser una funció amb menys condicions que
varPower encara que menys potent

fML_I_He1 <- formula(He1 ~ 1)

```

```

fRE_RI <- formula(~1|Lot)
Comp_I_RI_W_MD_He1 <- lapply(1:length(Av_DS_MD_list), function(p){
  Comp_W_LM(fML_I_He1, fRE_RI, Av_DS_MD_list[[p]], 0, 2, 0)
})
names(Comp_I_RI_W_MD_He1) <- names(Av_DS_MD_list)
Comp_I_RI_W_MD_He1_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_He1<-exactRLRT(lme(fML_I_He1, random = ~1|Lot, data =
Av_DS_MD_list[[p]]), method="REML",na.action=na.omit))
})
names(Comp_I_RI_W_MD_He1_RLRT) <- names(Av_DS_MD_list)

fML_I_He2 <- formula(He2 ~ 1)
fRE_RI <- formula(~1|Lot)
Comp_I_RI_W_MD_He2 <- lapply(1:length(Av_DS_MD_list), function(p){
  Comp_W_LM(fML_I_He2, fRE_RI, Av_DS_MD_list[[p]], 0, 2, 0)
})
names(Comp_I_RI_W_MD_He2) <- names(Av_DS_MD_list)
Comp_I_RI_W_MD_He2_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_He2<-exactRLRT(lme(fML_I_He2, random = ~1|Lot, data =
Av_DS_MD_list[[p]]), method="REML",na.action=na.omit))
})
names(Comp_I_RI_W_MD_He2_RLRT) <- names(Av_DS_MD_list)

fML_I_He3 <- formula(He3 ~ 1)
fRE_RI <- formula(~1|Lot)
Comp_I_RI_W_MD_He3 <- lapply(1:length(Av_DS_MD_list), function(p){
  Comp_W_LM(fML_I_He3, fRE_RI, Av_DS_MD_list[[p]], 0, 2, 0)
})
names(Comp_I_RI_W_MD_He3) <- names(Av_DS_MD_list)
Comp_I_RI_W_MD_He3_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_He3<-exactRLRT(lme(fML_I_He3, random = ~1|Lot, data =
Av_DS_MD_list[[p]]), method="REML",na.action=na.omit))
})
names(Comp_I_RI_W_MD_He3_RLRT) <- names(Av_DS_MD_list)

```
```
`{r MD ML IS RI So}
#Segons els models trobats s'ajusta per So1 IS RI, So2 IS RI i So3 IS
RIS. ENs centrem directament en el model REML per simplificar els
càlculs

Comp_IS_RI_MD_So1 <- lapply(1:length(Av_DS_MD_list), function(p){
  lme(So1 ~ 1 + Temps, random = ~1|Lot,control=ctrl,
       method="REML",data=Av_DS_MD_list[[p]],na.action=na.omit)
})
names(Comp_IS_RI_MD_So1) <- names(Av_DS_MD_list)
Comp_IS_RI_MD_So1_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_So1<-exactRLRT(Comp_IS_RI_MD_So1[[p]])
})
names(Comp_IS_RI_MD_So1_RLRT) <- names(Av_DS_MD_list)

Comp_IS_RI_MD_So2 <- lapply(1:length(Av_DS_MD_list), function(p){
  lme(So3 ~ 1 + Temps, random = ~1|Lot,control=ctrl,
       method="REML",data=Av_DS_MD_list[[p]],na.action=na.omit)
})
names(Comp_IS_RI_MD_So2) <- names(Av_DS_MD_list)
Comp_IS_RI_MD_So2_RLRT <- lapply(1:length(Av_DS_MD_list), function(p){
  eREML_So2<-exactRLRT(Comp_IS_RI_MD_So2[[p]])
})

```

```

names(Comp_IS RI MD So2 RLRT) <- names(Av_DS MD list)

#En el cas de múltiples efectes aleatoris fem el resultat de l'anova
de comparació entre el model RI i RIS + el contrast RLRT del model RI
Comp_IS RI MD So3 <- lapply(1:length(Av_DS MD list), function(p){
  lme(So3 ~ 1 + Temps, random = ~1|Lot, control=ctrl,
      method="REML", data=Av_DS MD list[[p]], na.action=na.omit)
})
names(Comp_IS RI MD So3) <- names(Av_DS MD list)
Comp_IS RIS MD So3 <- lapply(1:length(Av_DS MD list), function(p){
  lme(So3 ~ 1 + Temps, random = ~1+Temps|Lot, control=ctrl,
      method="REML", data=Av_DS MD list[[p]], na.action=na.omit)
})
names(Comp_IS RIS MD So3) <- names(Av_DS MD list)

Comp_IS RIS MD So3 RLRT <- lapply(1:length(Av_DS MD list), function(p){
  anova(Comp_IS RI MD So3[[p]], Comp_IS RIS MD So3[[p]])
})
names(Comp_IS RIS MD So3 RLRT) <- names(Av_DS MD list)
Comp_IS RI MD So3 RLRT <- lapply(1:length(Av_DS MD list), function(p){
  eREML_So3<-exactRLRT(Comp_IS RI MD So3[[p]])
})
names(Comp_IS RI MD So3 RLRT) <- names(Av_DS MD list)
```

AIC/BIC/Sigma

```r
`{r Resum MD ML Ho}
Ho1_MD_R <- ConvList(Comp_I RI MD Ho1)
s<-seq(1:3)
repeat {
  s<-c(s,s[seq(from=(length(s)-2),to=length(s))]+6)
  if (length(s)>=length(Ho1_MD_R)/2){
    break
  }
}
Ho1_MD_R <- Ho1_MD_R[s]
names(Ho1_MD_R) <-
paste(rep(names(Comp_I RI MD Ho1),each=3),names(Ho1_MD_R))

ML_Resum(Ho1_MD_R, "Ho1")

Ho2_MD_R <- ConvList(Comp_I RI MD Ho2)
s<-seq(1:3)
repeat {
  s<-c(s,s[seq(from=(length(s)-2),to=length(s))]+6)
  if (length(s)>=length(Ho2_MD_R)/2){
    break
  }
}
Ho2_MD_R <- Ho2_MD_R[s]
names(Ho2_MD_R) <-
paste(rep(names(Comp_I RI MD Ho2),each=3),names(Ho2_MD_R))

ML_Resum(Ho2_MD_R, "Ho2")
```

```

Comentaris:

+ Ho1: El núvol de punts aparentment ho segueix essent encara que eliminis valors. Les possibles variacions en el model poden ser per

l'eliminació concreta que s'ha obtingut en aquesta simulació i podria ser una altra en un altre cas (es podria confirmar fent bootstrap en futurs anàlisis).

+ Ho2: Aparentment al tenir més dades perdudes hi ha la mateixa error estàndard residual, però augmenta el AIC i BIC (els models es tornen més ineficients) a nivells significatius.

```
```{r Resum MD ML He}
He1_MD_R <- ConvList(Comp_I_RI_W_MD_He1)
s<-seq(from=7, to=length(He1_MD_R), by=12)

He1_MD_R <- He1_MD_R[s]
names(He1_MD_R) <- paste(names(Comp_I_RI_W_MD_He1), names(He1_MD_R))

ML_Resum(He1_MD_R, "He1")

He2_MD_R <- ConvList(Comp_I_RI_W_MD_He2)
s<-seq(from=7, to=length(He2_MD_R), by=12)

He2_MD_R <- He2_MD_R[s]
names(He2_MD_R) <- paste(names(Comp_I_RI_W_MD_He2), names(He2_MD_R))

ML_Resum(He2_MD_R, "He2")

He3_MD_R <- ConvList(Comp_I_RI_W_MD_He3)
s<-seq(from=7, to=length(He3_MD_R), by=12)

He3_MD_R <- He3_MD_R[s]
names(He3_MD_R) <- paste(names(Comp_I_RI_W_MD_He3), names(He3_MD_R))

ML_Resum(He3_MD_R, "He3")
```

```

Comentaris:

+ He1/He2/He3: Mentre que la error estàndard residual no sembla seguir un patró concret (possiblement té a veure amb l'aleatorietat concreta que es faci), AIC i BIC semblen disminuir al tenir més dades perdudes. És contradictori, però possiblement es deu a que d'alguna manera l'eliminació de dades fa disminuir l'heterogeneitat de valors acotant models més exactes (falsament).

```
```{r Resum MD ML So}
So1_MD_R <- Comp_IS_RI_MD_So1
names(So1_MD_R)      <-      paste(names(Comp_IS_RI_MD_So1), c("IS      RI
REML"), sep=" ")

ML_Resum(So1_MD_R, "So1")

So2_MD_R <- Comp_IS_RI_MD_So2
names(So2_MD_R)      <-      paste(names(Comp_IS_RI_MD_So2), c("IS      RI
REML"), sep=" ")

ML_Resum(So2_MD_R, "So2")

So3_MD_R <- Comp_IS_RIS_MD_So3
names(So3_MD_R)      <-      paste(names(Comp_IS_RIS_MD_So3), c("IS      RIS
REML"), sep=" ")

ML_Resum(So3_MD_R, "So3")
```

```

Comentaris: Sembla haver un patró clar de baixada dels indicadors AIC/BIC en els models a mesura que hi ha més absència de dades. No hauria de ser el normal ja que l'absència de dades habitualment és un impediment per tenir un bon model. Possiblement en aquest cas el model s'ajusta més correctament a les dades que queden tot i que és probable que el resultat sigui més esbiaixat.

### ### Contrast RLRT

Comparatiu de la prova de significació de l'efecte aleatori prenent com a model vàlid el model calcular per ML amb REML:

```
```{r MD ML I RI Ho I resum RLRT}
HoVars <- c("Ho1", "Ho2")

MD_I_RI_Ho_REML_RLRT      <- data.frame(Dataset      =
paste(rep(HoVars,each=length(Comp_I_RI_MD_Ho1_RLRT)),           paste("I
RI", "REML", sep=" ")))

MD_I_RI_Ho_REML_RLRT$VP          <-
rep(names(Comp_I_RI_MD_Ho1_RLRT),length(HoVars))

Comp_MD_RI_Ho_0 <- list(Comp_I_RI_MD_Ho1_RLRT, Comp_I_RI_MD_Ho2_RLRT)
Comp_MD_RI_Ho <- ConvList(Comp_MD_RI_Ho_0)

MD_I_RI_Ho_REML_RLRT$p_valor      <-
sapply(1:length(Comp_MD_RI_Ho), function(l1){
  if (class(Comp_MD_RI_Ho[[l1]])!="htest"){
    return("-")
  } else {
    round(Comp_MD_RI_Ho[[l1]]$p.value,4)
  }
})

ggplot(data=MD_I_RI_Ho_REML_RLRT, aes(x=Dataset, y=p_valor, fill=VP))
+
  geom_bar(stat="identity", position=position_dodge())+
  scale_fill_brewer(palette="Oranges") + theme_minimal() +
  labs(title="Comp. RLRT amb VP",y="p-valor RLRT") +
  theme(text = element_text(size=10),axis.text.x = element_text(angle=80,size = 10,hjust=0))
```

```

Comentaris:

- + Ho1: L'efecte aleatori per estrat de Lot és no significatiu en general al haver núvol de punts aleatori. Possiblement disminueix al augmentar els valors perduts pel fals efecte de aleatorietat seguint patrons concrets.
- + Ho2: L'efecte aleatori resulta significatiu en tots els casos. Fins i tot amb pèrdua de dades de fins al 60% aquest conjunt resulta altament diferenciat per lot la mitja d'observacions.

```
```{r MD ML I RI He I resum RLRT}
HeVars <- c("He1", "He2", "He3")

MD_I_RI_W_He_REML_RLRT      <- data.frame(Dataset      =
paste(rep(HeVars,each=length(Comp_I_RI_W_MD_He1_RLRT))),           paste("I RI
W", "REML", sep=" ")))

```

```

MD_I_RI_W_He_REML_RLRT$VP <-
rep(names(Comp_I_RI_W_MD_He1_RLRT),length(HeVars))

Comp_MD_RI_W_He_0 <-
list(Comp_I_RI_W_MD_He1_RLRT,Comp_I_RI_W_MD_He2_RLRT,Comp_I_RI_W_MD_He
3_RLRT)
Comp_MD_RI_W_He <- ConvList(Comp_MD_RI_W_He_0)

MD_I_RI_W_He_REML_RLRT$p_valor <-
sapply(1:length(Comp_MD_RI_W_He),function(l1){
  if (class(Comp_MD_RI_W_He[[l1]])!="htest"){
    return("-")
  } else {
    round(Comp_MD_RI_W_He[[l1]]$p.value,4)
  }
})

ggplot(data=MD_I_RI_W_He_REML_RLRT,           aes(x=Dataset,           y=p_valor,
fill=VP)) +
  geom_bar(stat="identity", position=position_dodge())+
  scale_fill_brewer(palette="Oranges") + theme_minimal() +
  labs(title="Comp. RLRT amb VP",y="p-valor RLRT") +
  theme(text      = element_text(size=10),axis.text.x     =
element_text(angle=80,size = 10,hjust=0))
```

```

Comentaris:

+ He1: L'efecte aleatori perd significació al perdre dades el conjunt. El patró que detecta el model de la lleugera dependència del lot no es manté com en el model Ho2 al haver una dispersió molt més forta.  
+ He2/He3: L'efecte aleatori ja no era significatiu degut probablement a la alta dispersió dels punts i el canvi de punts fa variar aquesta significació. No es considera que sigui un patró genèric de significació en relació a la pèrdua de valors ja que pot ser més fruit de l'aleatorietat concreta dels punts retirats que ajusten millor l'efecte aleatori dels lots o pitjor.

```

```{r MD ML I RI So I resum RLRT}
SoVars <- c("So1","So2","So3")

MD_I_RI_S_So_REML_RLRT           <-           data.frame(Dataset      =
paste(rep(c(SoVars,"So3(RIS)"),
each=length(C
omp_IS_RI_MD_So1_RLRT)),           paste("IS
RI/RIS","REML",sep=" ")))

MD_I_RI_S_So_REML_RLRT$VP       <-           rep(names(Comp_IS_RI_MD_So1_RLRT),
(length(SoVars)+1))

Comp_MD_RI_S_So_0 <-
list(Comp_IS_RI_MD_So1_RLRT,Comp_IS_RI_MD_So2_RLRT,
     Comp_IS_RI_MD_So3_RLRT,Comp_IS_RIS_MD_So3_RL
RT)
Comp_MD_RI_S_So <- ConvList(Comp_MD_RI_S_So_0)

MD_I_RI_S_So_REML_RLRT$p_valor <-
sapply(1:length(Comp_MD_RI_S_So),function(l1){
  if (class(Comp_MD_RI_S_So[[l1]])[1]=="htest"){

```

```

        round(Comp_MD_RI_S_So[[11]]$p.value,4)
    } else {
      round(Comp_MD_RI_S_So[[11]]$"p-value"[2],4)
    }
  })

ggplot(data=MD_I_RI_S_So_REML_RLRT,           aes(x=Dataset,           y=p_valor,
fill=VP)) +
  geom_bar(stat="identity", position=position_dodge())+
  scale_fill_brewer(palette="Oranges") + theme_minimal() +
  labs(title="Comp. RLRT amb VP",y="p-valor RLRT") +
  theme(text   = element_text(size=10),axis.text.x   =
element_text(angle=80,size = 10,hjust=0))
```

```

Comentaris: Tots els efectes semblen significatius en els conjunts So2 i So3 independentment de la pèrdua de dades. Semblen doncs necessaris igualment per explicar la variabilitat. En el model So1 segueix essent poc significatiu. La baixada segurament es deu a la pròpia aleatorietat de la simulació de pèrdua de dades.

### ### Paràmetres Efectes Aleatoris

Preneix igualment el model REML com a vàlid, veiem els canvis en els components de la variància de l'efecte aleatori (covariància de la matriu de variància-covariància entre repeticions) i la correlació que en resulta entre repeticions:

```

```{r Par. Ef. Aleat Ho}
#Generació de les llistes a mida de models per poder fer la taula de
paràmetres amb el model REML
Ho1_MD_R_2 <- ConvList(Comp_I_RI_MD_Ho1)
Ho2_MD_R_2 <- ConvList(Comp_I_RI_MD_Ho2)
Ho_MD_R_2_0 <- list(Ho1_MD_R_2, Ho2_MD_R_2)
Ho_MD_R_2 <- ConvList(Ho_MD_R_2_0)

s<-seq(from=6, to=length(Ho_MD_R_2), by=6)
Ho_MD_R_2r <- Ho_MD_R_2[s]

Ho_MD_RIpar           <-           data.frame(Dataset           =
paste(rep(HoVars,each=length(Comp_I_RI_MD_Ho1)),rep(names(Comp_I_RI_MD
_Ho1),2)))
Ho_MD_RIpar <- rbind(Ho_MD_RIpar, Ho_MD_RIpar)

Ho_MD_RIpar$Par_Tipus     <-       factor(rep(c("RI      Variància","RI
Correlació"),each=(nrow(Ho_MD_RIpar)/2)),
                                         levels=c("RI Variància","RI
Correlació"))

Ho_MD_RIpar_VarRI <- sapply(1:length(Ho_MD_R_2r),function(B){
  round(as.numeric(VarCorr(Ho_MD_R_2r[[B]])[1]),4)
})

Ho_MD_RIpar_CorrRI <- sapply(1:length(Ho_MD_R_2r),function(B){
  a<-getVarCov(Ho_MD_R_2r[[B]],type="marginal")
  b<-cov2cor(a[[1]])
  return(round(b[1,2],4))
})
```

```

```

fact <- if(mean(abs(Ho_MD_RIpar_VarRI)) >=
mean(abs(Ho_MD_RIpar_CorrRI))){ #Es fa un càlcul del factor més adient
per graficar les 2 escales en el gràfic
 10^(round(log10(abs(mean(Ho_MD_RIpar_VarRI))/abs(mean(Ho_MD_RIpar_-
CorrRI)))))}
} else {
 1/(10^(round(log10(abs(mean(Ho_MD_RIpar_CorrRI))/abs(mean(Ho_MD_RI-
par_VarRI))))))
}

if (fact==0){
 fact <-0.0001
}

Ho_MD_RIpar_CorrRI <- Ho_MD_RIpar_CorrRI*fact

Ho_MD_RIpar$Par <- c(Ho_MD_RIpar_VarRI,Ho_MD_RIpar_CorrRI)

ggplot(data=Ho_MD_RIpar, aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI",y="Covariància(Var.-
RI)") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Corr.(RI)") +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

```

```

Comentaris:

- + Ho1: Variacions probablament degut a l'aleatorietat concreta de pèrdua de dades.
- + Ho2: La centralitat de punts per Lot fa que tot i la pèrdua de dades es mantingui en el model el grau de covariància/correlació entre repeticions degut a l'efecte aleatori.

```

```{r Par. Ef. Aleat He}
#Generació de les llistes a mida de models per poder fer la taula de
paràmetres amb el model REML
He1_MD_R_2 <- ConvList(Comp_I_RI_W_MD_He1)
He2_MD_R_2 <- ConvList(Comp_I_RI_W_MD_He2)
He3_MD_R_2 <- ConvList(Comp_I_RI_W_MD_He3)
He_MD_R_2_0 <- list(He1_MD_R_2,He2_MD_R_2,He3_MD_R_2)
He_MD_R_2 <- ConvList(He_MD_R_2_0)

s<-seq(from=8, to=length(He_MD_R_2), by=12)
He_MD_R_2r <- He_MD_R_2[s]

He_MD_RIpar <- data.frame(Dataset =
paste(rep(HeVars,each=length(Comp_I_RI_W_MD_He1)),rep(names(Comp_I_RI_-
W_MD_He1),length(HeVars))))

He_MD_RIpar <- rbind(He_MD_RIpar,He_MD_RIpar)

He_MD_RIpar$Par_Tipus <- factor(rep(c("RI Variància","RI
Correlació"),each=(nrow(He_MD_RIpar)/2)),
levels=c("RI Variància","RI
Correlació"))

```

```

He_MD_RIpar_VarRI <- sapply(1:length(He_MD_R_2r), function(B){
 round(as.numeric(VarCorr(He_MD_R_2r[[B]])[1]),4)
})

He_MD_RIpar_CorrRI <- sapply(1:length(He_MD_R_2r), function(B){
 a<-getVarCov(He_MD_R_2r[[B]],type="marginal")
 b<-cov2cor(a[[1]])
 return(round(b[1,2],4))
})

fact <- if(mean(abs(He_MD_RIpar_VarRI)) >=
mean(abs(He_MD_RIpar_CorrRI))){ #Es fa un càcul del factor més adient
per graficar les 2 escales en el gràfic
 10^(round(log10(abs(mean(He_MD_RIpar_VarRI))/abs(mean(He_MD_RIpar_CorrRI)))))
} else {
 1/(10^(round(log10(abs(mean(He_MD_RIpar_CorrRI))/abs(mean(He_MD_RIpar_VarRI))))))
}

if (fact==0){
 fact <-0.0001
}

He_MD_RIpar_CorrRI <- He_MD_RIpar_CorrRI*fact

He_MD_RIpar$Par <- c(He_MD_RIpar_VarRI,He_MD_RIpar_CorrRI)

ggplot(data=He_MD_RIpar, aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI",y="Covariància(Var.RI)") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

```

```

Comentaris:

+ He1: El conjunt que té certa significància l'efecte aleatori mostra un nivell de covariància més alt i de correlació. Curiosament semblaria que la covariància augmenta amb la pèrdua de valors i la correlació disminueix. És a dir que possiblement el model dona una càrrega de l'explicació de la variabilitat més alta a l'efecte aleatori, però és incapaç d'explicar-lo a nivell de correlació entre repeticions. Hem de tenir en compte que en aquest cas també s'afegeix la funció de modulació de la variància.

+ He2: Efecte semblant a He1.

+ He3: La dispersió d'aquest conjunt fa que la correlació entre repeticions es mantingui sempre baixa tot i que en els models amb més pèrdua de dades el model calcula una covariància de l'efecte aleatori alta. Possiblement pot ser un fals patró com s'ha anat comentat en alguns casos.

```

```{r Par. Ef. Aleat So}
#Prenem la correlació entre els punts més propers com a referencia
#Generació de les llistes a mida de models per poder fer la taula de
paràmetres amb el model REML

```

```

So1_MD_R_2 <- ConvList(Comp_IS_RI_MD_So1)
So2_MD_R_2 <- ConvList(Comp_IS_RI_MD_So2)
So3_MD_R_2 <- ConvList(Comp_IS_RIS_MD_So3)
So_MD_R_2_0 <- list(So1_MD_R_2, So2_MD_R_2, So3_MD_R_2, So3_MD_R_2)
So_MD_R_2 <- ConvList(So_MD_R_2_0)

#A So3 s'ha de prendre la part de l'efecte aleatori de intercepció la
del temps per separat:
So_MD_RIpar <- data.frame(Dataset =
paste(rep(c(SoVars, "So3(t)"), each=length(Comp_IS_RI_MD_So1)),
rep(names(Comp_IS_RI_MD_So1),
,(length(SoVars)+1)))))

So_MD_RIpar <- rbind(So_MD_RIpar, So_MD_RIpar)

So_MD_RIpar$Par_Tipus <- factor(rep(c("RI Variància", "RI
Correlació"), each=(nrow(So_MD_RIpar)/2)),
levels=c("RI Variància", "RI
Correlació"))

So_MD_RIpar_VarRI <- c(
 sapply(1:(length(So_MD_R_2)-4), function(B){
 round(as.numeric(VarCorr(So_MD_R_2[[B]])[1]), 4)
 }),
 sapply((length(So_MD_R_2)-3):length(So_MD_R_2), function(B){
 round(as.numeric(VarCorr(So_MD_R_2[[B]])[2]), 4)
 })
)

So_MD_RIpar_CorrRI <- sapply(1:length(So_MD_R_2), function(B){
 a<-getVarCov(So_MD_R_2[[B]], type="marginal")
 b<-cov2cor(a[[1]])
 return(round(b[1,2], 4))
})

fact <- if(mean(abs(So_MD_RIpar_VarRI)) >=
mean(abs(So_MD_RIpar_CorrRI))){ #Es fa un càcul del factor més adient
per graficar les 2 escales en el gràfic
 10^(round(log10(abs(mean(So_MD_RIpar_VarRI))/abs(mean(So_MD_RIpar_
CorrRI)))))
} else {
 1/(10^(round(log10(abs(mean(So_MD_RIpar_CorrRI))/abs(mean(So_MD_RI
par_VarRI))))))
}

if (fact==0){
 fact <-0.0001
}

So_MD_RIpar_CorrRI <- So_MD_RIpar_CorrRI*fact

So_MD_RIpar$Par <- c(So_MD_RIpar_VarRI, So_MD_RIpar_CorrRI)

ggplot(data=So_MD_RIpar, aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI", y="Covariància(Var.
RI)") +
 scale_y_continuous(expand = c(0, 0), sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +

```

```
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))
```

```
```
```

No s'observa un patró claríssim entre els diferents conjunts en quant als efectes en la matriu de variància-covariància dels efectes aleatoris.

```
### Suma de Quadrats
```

Després de algunes proves, no es considera aquest apartat al estar tinguent en compte conjuntament models calculats per mínims quadrats i màxima versemblança.

```
### Intervals de Confiança de la predicción de mitges
```

No és senzill calcular els intervals de confiança de predicción en els models mixtes ja que la variabilitat depèn de més factors a part del factor residual a part de tenir el factor o factors aleatoris. Per duu a terme aquesta tasca dins el temps disponible per l'anàlisi estadístic es segueix les recomanacions de <http://www.remkoduursma.com/post/2017-06-15-bootpredictlme4/> i per fer-ho s'ajusten tots els models amb la funció `lmer`:

```
```{r MD lmer CI pred Ho Bootstrap}  
#A partir de la tècnica bootstrap amb l'estadístic t es pot deduir la
possible distribució i calcular els intervals de confiança aproximats
de la predicción
set.seed(7982)
lmer_I_RI_MD_Ho1 <- lapply(1:length(Av_DS_MD_list),function(p){
 lmer(Ho1 ~ 1 + (1|Lot),data=Av_DS_MD_list[[p]],REML=T,na.action=na.omit)
})
pred_lmer_I_RI_MD_Ho1 <- lapply(1:length(lmer_I_RI_MD_Ho1),function(p){
 predict(lmer_I_RI_MD_Ho1[[p]], newdata=data.frame(Lot="Lot 1"),
 se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_I_RI_MD_Ho2 <- lapply(1:length(Av_DS_MD_list),function(p){
 lmer(Ho2 ~ 1 + (1|Lot),data=Av_DS_MD_list[[p]],REML=T,na.action=na.omit)
})
pred_lmer_I_RI_MD_Ho2 <- lapply(1:length(lmer_I_RI_MD_Ho2),function(p){
 predict(lmer_I_RI_MD_Ho2[[p]], newdata=data.frame(Lot="Lot 1"),
 se.fit=TRUE, nsim=100)
})
```
```

```
```{r MD lmer CI pred Ho Bootstrap plots}
```

```
pred_lmer_Ho <- data.frame(Dataset =
rep(HoVars,each=length(Av_DS_MD_list)))
pred_lmer_Ho$VP <- rep(names(Av_DS_MD_list),length(HoVars))
pred_lmer_Ho$fit <- c()
 sapply(1:length(pred_lmer_I_RI_MD_Ho1),function(p){
 pred_lmer_I_RI_MD_Ho1[[p]]$fit
 }),
```

```

 sapply(1:length(pred_lmer_I_RI_MD_Ho2), function(p){
 pred_lmer_I_RI_MD_Ho2[[p]]$fit
 })
)

pred_lmer_Ho$LCI <- c(
 sapply(1:length(pred_lmer_I_RI_MD_Ho1), function(p){
 pred_lmer_I_RI_MD_Ho1[[p]]$ci.fit[1,]
 }),
 sapply(1:length(pred_lmer_I_RI_MD_Ho2), function(p){
 pred_lmer_I_RI_MD_Ho2[[p]]$ci.fit[1,]
 })
)

pred_lmer_Ho$HCl <- c(
 sapply(1:length(pred_lmer_I_RI_MD_Ho1), function(p){
 pred_lmer_I_RI_MD_Ho1[[p]]$ci.fit[2,]
 }),
 sapply(1:length(pred_lmer_I_RI_MD_Ho2), function(p){
 pred_lmer_I_RI_MD_Ho2[[p]]$ci.fit[2,]
 })
)

ggplot(pred_lmer_Ho, aes(x=VP, y=fit, group=Dataset, color=Dataset)) +
 geom_line() +
 geom_point(size=3) +
 geom_errorbar(aes(ymin=LCI, ymax=HCl), width=.3, size=.7,
 position=position_dodge(0.05)) +
 scale_color_brewer(palette="Pastel1")
```

```

Comentaris:

Tot i la variació de conjunt per les dades perdudes semblaria que l'interval de confiança per predir la mitja d'un lot qualsevol no variaria enormement. Ho sempre sembla variar més probablement pel factor aleatori aplicat que s'ha anat comentant.

```

```{r MD lmer CI pred He Bootstrap}
#A partir de la tècnica bootstrap amb l'estadístic t es pot deduir la
possible distribució i calcular els intervals de confiança aproximats
de la predicción. La manera d'ajustar la funció de variància en lmer no
és igual que lme, s'aproxima acotant els weights a partir de la
covariable Temps.
set.seed(7982)
lmer_I_RI_W_MD_He1 <- lapply(1:length(Av_DS_MD_list), function(p){
 lmer(He1 ~ 1 + (1|Lot), data=Av_DS_MD_list[[p]],
 weights = Temps, REML=T, na.action=na.omit)
})

pred_lmer_I_RI_W_MD_He1
lapply(1:length(lmer_I_RI_W_MD_He1), function(p){
 predict(lmer_I_RI_W_MD_He1[[p]], newdata=data.frame(Lot="Lot 1",
 Temps = 24), se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_I_RI_W_MD_He2 <- lapply(1:length(Av_DS_MD_list), function(p){
 lmer(He2 ~ 1 + (1|Lot), data=Av_DS_MD_list[[p]],
 weights = Temps, REML=T, na.action=na.omit)
})

```

```

})
pred_lmer_I_RI_W_MD_He2 <- lapply(1:length(lmer_I_RI_W_MD_He2), function(p){
 predict(lmer_I_RI_W_MD_He2[[p]], newdata=data.frame(Lot="Lot 1",
 Temps = 24), se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_I_RI_W_MD_He3 <- lapply(1:length(Av_DS_MD_list), function(p){
 lmer(He3 ~ 1 + (1|Lot), data=Av_DS_MD_list[[p]],
 weights = Temps, REML=T,na.action=na.omit)
})
pred_lmer_I_RI_W_MD_He3 <- lapply(1:length(lmer_I_RI_W_MD_He3), function(p){
 predict(lmer_I_RI_W_MD_He3[[p]], newdata=data.frame(Lot="Lot 1",
 Temps = 24), se.fit=TRUE, nsim=100)
})
```
``{r MD lmer CI pred He Bootstrap plots}

pred_lmer_He <- data.frame(Dataset =
rep(HeVars,each=length(Av_DS_MD_list)))
pred_lmer_He$VP <- rep(names(Av_DS_MD_list),length(HeVars))
pred_lmer_He$fit <- c(
  sapply(1:length(pred_lmer_I_RI_W_MD_He1), function(p){
    pred_lmer_I_RI_W_MD_He1[[p]]$fit
  }),
  sapply(1:length(pred_lmer_I_RI_W_MD_He2), function(p){
    pred_lmer_I_RI_W_MD_He2[[p]]$fit
  }),
  sapply(1:length(pred_lmer_I_RI_W_MD_He3), function(p){
    pred_lmer_I_RI_W_MD_He3[[p]]$fit
  })
)
pred_lmer_He$LCI <- c(
  sapply(1:length(pred_lmer_I_RI_W_MD_He1), function(p){
    pred_lmer_I_RI_W_MD_He1[[p]]$ci.fit[1,]
  }),
  sapply(1:length(pred_lmer_I_RI_W_MD_He2), function(p){
    pred_lmer_I_RI_W_MD_He2[[p]]$ci.fit[1,]
  }),
  sapply(1:length(pred_lmer_I_RI_W_MD_He3), function(p){
    pred_lmer_I_RI_W_MD_He3[[p]]$ci.fit[1,]
  })
)
pred_lmer_He$HCI <- c(
  sapply(1:length(pred_lmer_I_RI_W_MD_He1), function(p){
    pred_lmer_I_RI_W_MD_He1[[p]]$ci.fit[2,]
  }),
  sapply(1:length(pred_lmer_I_RI_W_MD_He2), function(p){
    pred_lmer_I_RI_W_MD_He2[[p]]$ci.fit[2,]
  }),
  sapply(1:length(pred_lmer_I_RI_W_MD_He3), function(p){
    pred_lmer_I_RI_W_MD_He3[[p]]$ci.fit[2,]
  })
)

```

```

p1<-ggplot(pred_lmer_He[pred_lmer_He$Dataset=="He1",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3)+
  geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3,size=.7,
                position=position_dodge(0.05))
p2<-ggplot(pred_lmer_He[pred_lmer_He$Dataset=="He2",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3)+
  geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3,size=.7,
                position=position_dodge(0.05))

p3<-ggplot(pred_lmer_He[pred_lmer_He$Dataset=="He3",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3)+
  geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3,size=.7,
                position=position_dodge(0.05))

grid.arrange(p1,p2,p3)

```

```

Comentaris:

No s'aprecia una variació molt gran entre els intervals de confiança de les prediccions tot i que seria recomanable repetir aquest anàlisi amb més detall al haver hagut d'alternar les funcions lme i lmer per practicitat de codi i temps disponible.

```

```{r MD lmer CI pred So Bootstrap}
#A partir de la tècnica bootstrap amb l'estadístic t es pot deduir la
possible distribució i calcular els intervals de confiança aproximats
de la predicció.
set.seed(7982)
lmer_IS_RI_MD_So1 <- lapply(1:length(Av_DS_MD_list),function(p){
  lmer(So1 ~ 1 + Temps + (1|Lot),data=Av_DS_MD_list[[p]],
       REML=T,na.action=na.omit)
})

pred_lmer_IS_RI_MD_So1                                     <-
lapply(1:length(lmer_IS_RI_MD_So1),function(p){
  predict(lmer_IS_RI_MD_So1[[p]], newdata=data.frame(Lot="Lot 1",
  Temps = 24), se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_IS_RI_MD_So2 <- lapply(1:length(Av_DS_MD_list),function(p){
  lmer(So2 ~ 1 + Temps + (1|Lot),data=Av_DS_MD_list[[p]],
       REML=T,na.action=na.omit)
})
pred_lmer_IS_RI_MD_So2                                     <-
lapply(1:length(lmer_IS_RI_MD_So2),function(p){
  predict(lmer_IS_RI_MD_So2[[p]], newdata=data.frame(Lot="Lot 1",
  Temps = 24), se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_IS_RIS_MD_So3 <- lapply(1:length(Av_DS_MD_list),function(p){

```

```

lmer(So3 ~ 1 + Temps + (1+Temps|Lot), data=Av_DS_MD_list[[p]],
      REML=T,na.action=na.omit,control = lmerControl(optimizer
="Nelder_Mead"))
})
pred_lmer_IS_RIS_MD_So3 <-
lapply(1:length(lmer_IS_RIS_MD_So3),function(p){
  predict(lmer_IS_RIS_MD_So3[[p]], newdata=data.frame(Lot="Lot 1",
  Temps = 24), se.fit=TRUE, nsim=100)
})

``{r MD lmer CI pred So Bootstrap plots}

pred_lmer_So <- data.frame(Dataset =
rep(SoVars,each=length(Av_DS_MD_list)))
pred_lmer_So$VP <- rep(names(Av_DS_MD_list),length(SoVars))
pred_lmer_So$fit <- c(
  sapply(1:length(pred_lmer_IS_RI_MD_So1),function(p){
    pred_lmer_IS_RI_MD_So1[[p]]$fit
  }),
  sapply(1:length(pred_lmer_IS_RI_MD_So2),function(p){
    pred_lmer_IS_RI_MD_So2[[p]]$fit
  }),
  sapply(1:length(pred_lmer_IS_RIS_MD_So3),function(p){
    pred_lmer_IS_RIS_MD_So3[[p]]$fit
  })
)

pred_lmer_So$LCI <- c(
  sapply(1:length(pred_lmer_IS_RI_MD_So1),function(p){
    pred_lmer_IS_RI_MD_So1[[p]]$ci.fit[1,]
  }),
  sapply(1:length(pred_lmer_IS_RI_MD_So2),function(p){
    pred_lmer_IS_RI_MD_So2[[p]]$ci.fit[1,]
  }),
  sapply(1:length(pred_lmer_IS_RIS_MD_So3),function(p){
    pred_lmer_IS_RIS_MD_So3[[p]]$ci.fit[1,]
  })
)

pred_lmer_So$HCI <- c(
  sapply(1:length(pred_lmer_IS_RI_MD_So1),function(p){
    pred_lmer_IS_RI_MD_So1[[p]]$ci.fit[2,]
  }),
  sapply(1:length(pred_lmer_IS_RI_MD_So2),function(p){
    pred_lmer_IS_RI_MD_So2[[p]]$ci.fit[2,]
  }),
  sapply(1:length(pred_lmer_IS_RIS_MD_So3),function(p){
    pred_lmer_IS_RIS_MD_So3[[p]]$ci.fit[2,]
  })
)

p1<-ggplot(pred_lmer_So[pred_lmer_So$Dataset=="So1",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3) +
  geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3,size=.7,
                position=position_dodge(0.05))
p2<-ggplot(pred_lmer_So[pred_lmer_So$Dataset=="So2",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +

```

```

geom_point(size=3)+
  geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3, size=.7,
  position=position_dodge(0.05))

p3<-ggplot(pred_lmer_So[pred_lmer_So$Dataset=="So3",],           aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3)+
  geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3, size=.7,
  position=position_dodge(0.05))

grid.arrange(p1,p2,p3)

```

```

Lleugeres diferències en la predicció, però sembla que l'efectivitat del model compensa la pèrdua de dades en els algoritmes utilitzats en el codi almenys.

#### # IMPUTACIÓ DE DADES PERDUDES

Es consideren alguns mètodes d'imputació per veure com compensen el model aprofitant les dades que s'han calculat de l'efecte de no tenir aquestes dades. Per simplificar es tindrà en compte únicament alguns dels mètodes que s'han fet servir per diagnosticar els efectes dels resultats:

- + Scatterplots i Gràfics de densitat inicials on es comparen les observacions.
- + Anàlisi de indicadors de qualitat AIC, BIC i error estàndard residual.
- + Predicció de valors en el temps final.

Es simplifica també les bases tractades prenent els casos on s'han vist possibles desviacions interessants de tractar:

- + Ho2
- + He2
- + He3
- + So2
- + So3

Es pren únicament un dels casos de pèrdua de dades prenent el del 40%. Un cas exagerat, però no tan inversemblant com el del 60% on habitualment ja no es continuaria l'estudi.

Tot i que es podrà veure en certa mesura, en aquest exercici no podem esperar comparar de manera molt detallada els diferents sistemes ja que cada un d'ells té moltes variables possibles a aplicar segons el tipus de context on estigui imputant dades, pel que es té en compte més en general l'eficàcia de imputar dades en relació a no fer-ho.

Es generen els objectes necessaris inicials:

```

```{r DF VP IMP}
Av_DS_MDIMP_list0 <- Av_DS_MD_list[c(1,3)]
Av_DS_MDIMP_list <- Av_DS_MDIMP_list0
IMP_Vars <- c("Ho2","He2","He3","So2","So3")

for(p in 1:(length(Av_DS_MDIMP_list0))){
```

```

  Av_DS_MDIMP_list[[p]]    <- subset(Av_DS_MDIMP_list[[p]], select=-
c(Ho1,He1,So1))
}

VP_DS <- Av_DS_MDIMP_list[[length(Av_DS_MDIMP_list0)]]
```

MODELS D'IMPUTACIÓ

KNN

L'algoritme utilitza la fórmula de la distància i concretament escollim la opció de tenir en compte la distància per calcular el pes del veí en el càlcul:

```

```{r kNN imp}
#S'aplica individualment per cada variable de resposta i després s'ajunten
KNN0 <- lapply(1:length(IMP_Vars), function(v){
 KNN(VP_DS[,c(1:3,(3+v))], k = 5, dist_var = colnames(VP_DS[,c(1:3,
(3+v))]), weight="auto",
 weightDist = T,imp_var=F, numFun = median)
})

VP_DS_kNN <- cbind(KNN0[[1]],sapply(2:length(IMP_Vars),function(v){
 KNN0[[v]][,4]
}))
colnames(VP_DS_kNN)[4:ncol(VP_DS_kNN)] <- IMP_Vars

Av_DS_MDIMP_list[[length(Av_DS_MDIMP_list)+1]] <- VP_DS_kNN
names(Av_DS_MDIMP_list)[length(Av_DS_MDIMP_list)] <- "40 % VP KNN Imp."
```

```

Regressió estocàstica

S'utilitza l'algoritme dins el paquet `MICE`:

```

```{r BSR imp}
BSR0 <- lapply(1:length(IMP_Vars), function(v){
 complete(mice(VP_DS[,c(1:3,(3+v))],method = "norm.nob", m =
1,print=F))
})

VP_DS_BSR <- cbind(BSR0[[1]],sapply(2:length(IMP_Vars),function(v){
 BSR0[[v]][,4]
}))
colnames(VP_DS_BSR)[4:ncol(VP_DS_BSR)] <- IMP_Vars

Av_DS_MDIMP_list[[length(Av_DS_MDIMP_list)+1]] <- VP_DS_BSR
names(Av_DS_MDIMP_list)[length(Av_DS_MDIMP_list)] <- "40 % VP BSR Imp."
```

```

Ajust de models lineals

Repetim el mateix que abans però amb la nova llista de conjunts de dades:

```

```{r MD ML I RI Ho2 IMP}```
```

```

Comp_I_RI_MDIMP_Ho2 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
 Comp_I_RI_LM("Ho2", Av_DS_MDIMP_list[[p]])
})

names(Comp_I_RI_MDIMP_Ho2) <- names(Av_DS_MDIMP_list)

fmHo2 <- formula(paste("Ho2", "~", 1))
Comp_I_RI_MDIMP_Ho2_RLRT <-
lapply(1:length(Av_DS_MDIMP_list), function(p){
 eREML_Ho2<-exactRLRT(lme(fmHo2, random = ~1|Lot, data =
Av_DS_MDIMP_list[[p]], method="REML",na.action=na.omit))
})

names(Comp_I_RI_MDIMP_Ho2_RLRT) <- names(Av_DS_MDIMP_list)
```

```
```{r MD ML I RI He IMP}
#Ajustarem per varExp al ser una funció amb menys condicions que
varPower encara que menys potent

fML_I_He2 <- formula(He2 ~ 1)
fRE_RI <- formula(~1|Lot)
Comp_I_RI_W_MDIMP_He2 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
{
  Comp_W_LM(fML_I_He2, fRE_RI, Av_DS_MDIMP_list[[p]], 0, 2, 0)
})
names(Comp_I_RI_W_MDIMP_He2) <- names(Av_DS_MDIMP_list)
Comp_I_RI_W_MDIMP_He2_RLRT <-
lapply(1:length(Av_DS_MDIMP_list), function(p){
  eREML_He2<-exactRLRT(lme(fML_I_He2, random = ~1|Lot, data =
Av_DS_MDIMP_list[[p]], method="REML",na.action=na.omit))
})
names(Comp_I_RI_W_MDIMP_He2_RLRT) <- names(Av_DS_MDIMP_list)

fML_I_He3 <- formula(He3 ~ 1)
fRE_RI <- formula(~1|Lot)
Comp_I_RI_W_MDIMP_He3 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
{
  Comp_W_LM(fML_I_He3, fRE_RI, Av_DS_MDIMP_list[[p]], 0, 2, 0)
})
names(Comp_I_RI_W_MDIMP_He3) <- names(Av_DS_MDIMP_list)
Comp_I_RI_W_MDIMP_He3_RLRT <-
lapply(1:length(Av_DS_MDIMP_list), function(p){
  eREML_He3<-exactRLRT(lme(fML_I_He3, random = ~1|Lot, data =
Av_DS_MDIMP_list[[p]], method="REML",na.action=na.omit))
})
names(Comp_I_RI_W_MDIMP_He3_RLRT) <- names(Av_DS_MDIMP_list)
```

```
```{r MD ML IS RI So IMP}
#Segons els models trobats s'ajusta per So1 IS RI, So2 IS RI i So3 IS
RIS. Ens centrem directament en el model REML per simplificar els
càlculs

Comp_IS_RI_MDIMP_So2 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
 lme(So3 ~ 1 + Temps, random = ~1|Lot,control=ctrl,
 method="REML",data=Av_DS_MDIMP_list[[p]],na.action=na.omit)
})
names(Comp_IS_RI_MDIMP_So2) <- names(Av_DS_MDIMP_list)

```

```

Comp_IS_RI_MDIMP_So2_RLRT <-
lapply(1:length(Av_DS_MDIMP_list), function(p){
 eREML_So2<-exactRLRT(Comp_IS_RI_MDIMP_So2[[p]])
})
names(Comp_IS_RI_MDIMP_So2_RLRT) <- names(Av_DS_MDIMP_list)

#En el cas de múltiples efectes aleatoris fem el resultat de l'anova
de comparació entre el model RI i RIS + el contrast RLRT del model RI
Comp_IS_RI_MDIMP_So3 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
 lme(So3 ~ 1 + Temps, random = ~1|Lot,control=ctrl,
 method="REML", data=Av_DS_MDIMP_list[[p]],na.action=na.omit)
})
names(Comp_IS_RI_MDIMP_So3) <- names(Av_DS_MDIMP_list)
Comp_IS_RIS_MDIMP_So3 <- lapply(1:length(Av_DS_MDIMP_list), function(p)
{
 lme(So3 ~ 1 + Temps, random = ~1+Temps|Lot,control=ctrl,
 method="REML", data=Av_DS_MDIMP_list[[p]],na.action=na.omit)
})
names(Comp_IS_RIS_MDIMP_So3) <- names(Av_DS_MDIMP_list)

Comp_IS_RIS_MDIMP_So3_RLRT <-
lapply(1:length(Av_DS_MDIMP_list), function(p){
 anova(Comp_IS_RI_MDIMP_So3[[p]],Comp_IS_RIS_MDIMP_So3[[p]])
})
names(Comp_IS_RIS_MDIMP_So3_RLRT) <- names(Av_DS_MDIMP_list)
Comp_IS_RI_MDIMP_So3_RLRT <-
lapply(1:length(Av_DS_MDIMP_list), function(p){
 eREML_So3<-exactRLRT(Comp_IS_RI_MDIMP_So3[[p]])
})
names(Comp_IS_RI_MDIMP_So3_RLRT) <- names(Av_DS_MDIMP_list)
```

## VISUALITZACIÓ RESULTATS

### Scatterplots i Density plots

```{r Complet Scatterplots IMP}
Av_DS_MDIMP_list <-
list(Av_DS_MDIMP_list[[1]],Av_DS_MDIMP_list[[2]],VP_DS_KNN,VP_DS_BSR)
names(Av_DS_MDIMP_list) <- c("DS" "Original" 0%
VP",paste("DS",names(Av_DS_MD_list)[3])),
 paste("DS",names(Av_DS_MD_list)[3],"kNN"),
 paste("DS",names(Av_DS_MD_list)[3],"BSR"))

labs_1 <-
matrix(paste(rep(IMP_Vars,each=length(Av_DS_MDIMP_list)),names(Av_DS_M
DIMP_list),sep=" "),ncol=length(IMP_Vars))
labs_2 <- matrix(paste(rep(IMP_Vars,each=length(Av_DS_MDIMP_list)),"s/
Lot",names(Av_DS_MDIMP_list),sep=" "),ncol=length(IMP_Vars))

Av_DS_MDIMP_plot_sc1 <- lapply(1:length(IMP_Vars),function(g){
 lapply(1:length(Av_DS_MDIMP_list),function(p){
 ggplot(Av_DS_MDIMP_list[[p]], aes(x=Temps, y=Av_DS_MDIMP_list[[p]]
[,paste(IMP_Vars[g])])) + geom_point() +
 geom_smooth(linetype="dashed") + labs(title=labs_1[p,g], y =
"Observacions") +
 geom_miss_point()
 })
})
```

```

```

Av_DS_MDIMP_plot_sc2 <- lapply(1:length(IMP_Vars), function(g){
  lapply(1:length(Av_DS_MDIMP_list), function(p){
    ggplot(Av_DS_MDIMP_list[[p]], aes(x=Temps, y=Av_DS_MDIMP_list[[p]]
    [,paste(IMP_Vars[g])]), color=Lot, group=Lot)) +
      geom_point() + geom_smooth(method="lm", se=F) +
      labs(title=labs_2[p,g], y = "Observacions") +
      geom_miss_point()
  })
})

Av_DS_MDIMP_ydens_plot <- lapply(1:length(IMP_Vars), function(g){
  lapply(1:length(Av_DS_MDIMP_list), function(p){
    ggplot(Av_DS_MDIMP_list[[p]], aes(x=Av_DS_MDIMP_list[[p]]
    [,paste(IMP_Vars[g])])) +
      geom_density(color="darkblue", fill="lightblue") +
      geom_vline(aes(xintercept=mean(IMP_Vars[g])), color="blue",
      linetype="dashed", size=1) +
      labs(title=labs_1[p,g], x = "Observacions")
  })
})

lapply(1:length(IMP_Vars), function(g){
  grid.arrange(grobs = Av_DS_MDIMP_plot_sc1[[g]])
})

lapply(1:length(IMP_Vars), function(g){ #Per aquest gràfic només prenem
  grid.arrange(grobs = Av_DS_MDIMP_plot_sc2[[g]])
})

lapply(1:length(IMP_Vars), function(g){
  grid.arrange(grobs = Av_DS_MDIMP_ydens_plot[[g]])
})

```

És interessant veure com es resolen els punts a vegades de manera més encertada o menys. Donaria la impressió que en els conjunts amb patrons de regressió més definits o més centrats en cada lot, l'aproximació per BSR dona més bon efecte, mentre que en altres conjunts sense patrons de regressió dona més bon resultats kNN

```

### AIC/BIC/Sigma

```{r Resum MD ML Ho IMP}
Ho2_MDIMP_R <- ConvList(Comp_I_RI_MDIMP_Ho2)
s<-seq(1:3)
repeat {
 s<-c(s,s[seq(from=(length(s)-2),to=length(s))]+6)
 if (length(s)>=length(Ho2_MDIMP_R)/2){
 break
 }
}
Ho2_MDIMP_R <- Ho2_MDIMP_R[s]
names(Ho2_MDIMP_R) <-
paste(rep(names(Comp_I_RI_MDIMP_Ho2),each=3),names(Ho2_MDIMP_R))

ML_Resum(Ho2_MDIMP_R,"Ho2")
```

```

Comentaris:

+ Ho2: Tant per la part de AIC i BIC com la error estàndard residual, sembla que en el cas de BSR compensa millor les dades perdudes en aquest cas, cosa que ja semblava en els gràfics inicials.

```
```{r Resum MD ML He IMP}
He2_MDIMP_R <- ConvList(Comp_I_RI_W_MDIMP_He2)
s<-seq(from=7, to=length(He2_MDIMP_R), by=12)

He2_MDIMP_R <- He2_MDIMP_R[s]
names(He2_MDIMP_R) <- paste(names(Comp_I_RI_W_MDIMP_He2), names(He2_MDIMP_R))

ML_Resum(He2_MDIMP_R, "He2")

He3_MDIMP_R <- ConvList(Comp_I_RI_W_MDIMP_He3)
s<-seq(from=7, to=length(He3_MDIMP_R), by=12)

He3_MDIMP_R <- He3_MDIMP_R[s]
names(He3_MDIMP_R) <- paste(names(Comp_I_RI_W_MDIMP_He3), names(He3_MDIMP_R))

ML_Resum(He3_MDIMP_R, "He3")
````
```

Comentaris:

+ He2/He3: Semblaria ajustar millor en aquest aspecte el model amb kNN a nivell de error estàndard residual, tot i que per part dels indicadors AIC i BIC estarien situats a nivells similars.

```
```{r Resum MD ML So IMP}
So2_MDIMP_R <- Comp_IS_RI_MDIMP_So2
names(So2_MDIMP_R) <- paste(names(Comp_IS_RI_MDIMP_So2), c("IS RI REML"), sep=" ")

ML_Resum(So2_MDIMP_R, "So2")

So3_MDIMP_R <- Comp_IS_RIS_MDIMP_So3
names(So3_MDIMP_R) <- paste(names(Comp_IS_RIS_MDIMP_So3), c("IS RIS REML"), sep=" ")

ML_Resum(So3_MDIMP_R, "So3")
````
```

Comentaris:

+ So2: Semblaria clar en aquesta part que el model que ajusta millor és el corregit per BSR i de fet és una correcció basada en una regressió, cosa que tindria sentit al ser un model amb marcada regressió per lot.

+ So3: La aleatorietat de pendents fa que els mètodes utilitzats per suprir les dades faltants no siguin efectius en aquest cas donant resultats dels 3 indicadors significativament més diferents que l'ajustat amb eliminació dels valors perduts.

Contrast RLRT

Comparatiu de la prova de significació de l'efecte aleatori prenent com a model vàlid el model calcular per ML amb REML:

```
```{r MD ML I RI Ho I resum RLRT IMP}
HoVars <- c("Ho2")
```

```

MDIMP_I_RI_Ho_REML_RLRT <- data.frame(Dataset =
paste(rep(HoVars,each=length(Comp_I_RI_MDIMP_Ho2_RLRT))), paste("I
RI", "REML", sep=" "))
MDIMP_I_RI_Ho_REML_RLRT$VP <-
rep(names(Comp_I_RI_MDIMP_Ho2_RLRT),length(HoVars))

Comp_MDIMP_RI_Ho_0 <- list(Comp_I_RI_MDIMP_Ho2_RLRT)
Comp_MDIMP_RI_Ho <- ConvList(Comp_MDIMP_RI_Ho_0)

MDIMP_I_RI_Ho_REML_RLRT$p_valor <-
sapply(1:length(Comp_MDIMP_RI_Ho),function(l1){
 if (class(Comp_MDIMP_RI_Ho[[l1]])!="htest"){
 return("-")
 } else {
 round(Comp_MDIMP_RI_Ho[[l1]]$p.value,4)
 }
})

ggplot(data=MDIMP_I_RI_Ho_REML_RLRT, aes(x=Dataset, y=p_valor,
fill=VP)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Oranges") + theme_minimal() +
 labs(title="Comp. RLRT amb VP",y="p-valor RLRT") +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))
```

```

Comentaris:

```

+ Ho2: L'efecte aleatori resulta significatiu en tots els casos.

```{r MD ML I RI He I resum RLRT IMP}
HeVars <- c("He2", "He3")

MDIMP_I_RI_W_He_REML_RLRT <- data.frame(Dataset =
paste(rep(HeVars,each=length(Comp_I_RI_W_MDIMP_He2_RLRT))), paste("I RI
W", "REML", sep=" "))

MDIMP_I_RI_W_He_REML_RLRT$VP <-
rep(names(Comp_I_RI_W_MDIMP_He2_RLRT),length(HeVars))

Comp_MDIMP_RI_W_He_0 <-
list(Comp_I_RI_W_MDIMP_He2_RLRT,Comp_I_RI_W_MDIMP_He3_RLRT)
Comp_MDIMP_RI_W_He <- ConvList(Comp_MDIMP_RI_W_He_0)

MDIMP_I_RI_W_He_REML_RLRT$p_valor <-
sapply(1:length(Comp_MDIMP_RI_W_He),function(l1){
 if (class(Comp_MDIMP_RI_W_He[[l1]])!="htest"){
 return("-")
 } else {
 round(Comp_MDIMP_RI_W_He[[l1]]$p.value,4)
 }
})

ggplot(data=MDIMP_I_RI_W_He_REML_RLRT, aes(x=Dataset, y=p_valor,
fill=VP)) +
 geom_bar(stat="identity", position=position_dodge())+

```

```

scale_fill_brewer(palette="Oranges") + theme_minimal() +
 labs(title="Comp. RLRT amb VP",y="p-valor RLRT") +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))
```

```

Comentaris:

+ He2/He3: Cap dels 2 mètodes per suprir valors semblaria igualar la original i inclús el model amb els valors eliminats semblaria tenir més semblança.

```

```{r MD ML I RI So I resum RLRT IMP}
SoVars <- c("So2","So3")

MDIMP_I_RI_S_So_REML_RLRT <- data.frame(Dataset =
paste(rep(c(SoVars,"So3(RIS)"), each=length(C
omp_IS_RI_MDIMP_So2_RLRT)), paste("IS
RI/RIS","REML",sep=" ")))

MDIMP_I_RI_S_So_REML_RLRT$VP <- rep(names(Comp_IS_RI_MDIMP_So2_RLRT),
(length(SoVars)+1))

Comp_MDIMP_RI_S_So_0 <- list(Comp_IS_RI_MDIMP_So2_RLRT,
 Comp_IS_RI_MDIMP_So3_RLRT,Comp_IS_RIS_MDIMP_
So3_RLRT)
Comp_MDIMP_RI_S_So <- ConvList(Comp_MDIMP_RI_S_So_0)

MDIMP_I_RI_S_So_REML_RLRT$p_valor <-
sapply(1:length(Comp_MDIMP_RI_S_So),function(l1){
 if (class(Comp_MDIMP_RI_S_So[[l1]])[1]=="htest"){
 round(Comp_MDIMP_RI_S_So[[l1]]$p.value,4)
 } else {
 round(Comp_MDIMP_RI_S_So[[l1]]$"p-value"[2],4)
 }
})

ggplot(data=MDIMP_I_RI_S_So_REML_RLRT, aes(x=Dataset, y=p_valor,
fill=VP)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Oranges") + theme_minimal() +
 labs(title="Comp. RLRT amb VP",y="p-valor RLRT") +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))
```

```

Comentaris: Tots els efectes semblen significatius en els conjunts So2 i So3 independentment de la pèrdua de dades. Semblen doncs necessaris igualment per explicar la variabilitat. Els dos sistemes de correcció de dades donen models encara més diferents que el de l'eliminació de dades perdudes en el cas de So3. Possiblement al tenir una estructura més complexa caldria un mètode més addient per substitució de valors.

Paràmetres Efectes Aleatoris

Prenent igualment el model REML com a vàlid, veiem els canvis en els components de la variància de l'efecte aleatori (covariància de la matriu de variància-covariància entre repeticions) i la correlació que en resulta entre repeticions:

```

```{r Par. Ef. Aleat Ho IMP}
#Generació de les llistes a mida de models per poder fer la taula de
paràmetres amb el model REML
Ho2_MDIMP_R_2 <- ConvList(Comp_I_RI_MDIMP_Ho2)
Ho_MDIMP_R_2_0 <- list(Ho2_MDIMP_R_2)
Ho_MDIMP_R_2 <- ConvList(Ho_MDIMP_R_2_0)

s<-seq(from=6, to=length(Ho_MDIMP_R_2), by=6)
Ho_MDIMP_R_2r <- Ho_MDIMP_R_2[s]

Ho_MDIMP_RIpar <- data.frame(Dataset =
paste(rep(HoVars,each=length(Comp_I_RI_MDIMP_Ho2)),rep(names(Comp_I_RI
_MDIMP_Ho2),2)))

Ho_MDIMP_RIpar <- rbind(Ho_MDIMP_RIpar, Ho_MDIMP_RIpar)

Ho_MDIMP_RIpar$Par_Tipus <- factor(rep(c("RI Variància", "RI
Correlació"), each=(nrow(Ho_MDIMP_RIpar)/2)),
levels=c("RI Variància", "RI
Correlació"))

Ho_MDIMP_RIpar_VarRI <- sapply(1:length(Ho_MDIMP_R_2r), function(B){
 round(as.numeric(VarCorr(Ho_MDIMP_R_2r[[B]])[1]),4)
})

Ho_MDIMP_RIpar_CorrRI <- sapply(1:length(Ho_MDIMP_R_2r), function(B){
 a<-getVarCov(Ho_MDIMP_R_2r[[B]], type="marginal")
 b<-cov2cor(a[[1]])
 return(round(b[1,2],4))
})

fact <- if(mean(abs(Ho_MDIMP_RIpar_VarRI)) >=
mean(abs(Ho_MDIMP_RIpar_CorrRI))){ #Es fa un càcul del factor més
adient per graficar les 2 escales en el gràfic
 10^(round(log10(abs(mean(Ho_MDIMP_RIpar_VarRI))/abs(mean(Ho_MDIMP_
RIpar_CorrRI)))))
} else {
 1/(10^(round(log10(abs(mean(Ho_MDIMP_RIpar_CorrRI))/abs(mean(Ho_MD
IMP_RIpar_VarRI))))))
}

if (fact==0){
 fact <-0.0001
}

Ho_MDIMP_RIpar_CorrRI <- Ho_MDIMP_RIpar_CorrRI*fact

Ho_MDIMP_RIpar$Par <- c(Ho_MDIMP_RIpar_VarRI, Ho_MDIMP_RIpar_CorrRI)

ggplot(data=Ho_MDIMP_RIpar, aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI", y="Covariància(Var.
RI)") +
 scale_y_continuous(expand = c(0, 0), sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +
 theme(text = element_text(size=10), axis.text.x =
element_text(angle=80, size = 10, hjust=0))

```

```

Comentaris:

+ Ho2: La centralitat de punts per Lot fa que tot i la pèrdua de dades es mantingui en el model el grau de covariància/correlació entre repeticions degut a l'efecte aleatori.

```
```{r Par. Ef. Aleat He IMP}
#Generació de les llistes a mida de models per poder fer la taula de paràmetres amb el model REML

He2_MDIMP_R_2 <- ConvList(Comp_I_RI_W_MDIMP_He2)
He3_MDIMP_R_2 <- ConvList(Comp_I_RI_W_MDIMP_He3)
He_MDIMP_R_2_0 <- list(He2_MDIMP_R_2,He3_MDIMP_R_2)
He_MDIMP_R_2 <- ConvList(He_MDIMP_R_2_0)

s<-seq(from=8, to=length(He_MDIMP_R_2), by=12)
He_MDIMP_R_2r <- He_MDIMP_R_2[s]

He_MDIMP_RIpar <- data.frame(Dataset =
paste(rep(HeVars,each=length(Comp_I_RI_W_MDIMP_He2)),rep(names(Comp_I_RI_W_MDIMP_He2),length(HeVars))))
```

He\_MDIMP\_RIpar <- rbind(He\_MDIMP\_RIpar,He\_MDIMP\_RIpar)

He\_MDIMP\_RIpar\$Par\_Tipus <- factor(rep(c("RI Variància","RI Correlació"),each=(nrow(He\_MDIMP\_RIpar)/2)),
levels=c("RI Variància","RI Correlació"))

He\_MDIMP\_RIpar\_VarRI <- sapply(1:length(He\_MDIMP\_R\_2r),function(B){
round(as.numeric(VarCorr(He\_MDIMP\_R\_2r[[B]])[1]),4)
})

He\_MDIMP\_RIpar\_CorrRI <- sapply(1:length(He\_MDIMP\_R\_2r),function(B){
a<-getVarCov(He\_MDIMP\_R\_2r[[B]],type="marginal")
b<-cov2cor(a[[1]])
return(round(b[1,2],4))
})

fact <- if(mean(abs(He\_MDIMP\_RIpar\_VarRI)) >=
mean(abs(He\_MDIMP\_RIpar\_CorrRI))){ #Es fa un càcul del factor més adient per graficar les 2 escales en el gràfic
10^(round(log10(abs(mean(He\_MDIMP\_RIpar\_VarRI))/abs(mean(He\_MDIMP\_RIpar\_CorrRI)))))}
else {
1/(10^(round(log10(abs(mean(He\_MDIMP\_RIpar\_CorrRI))/abs(mean(He\_MDIMP\_RIpar\_VarRI))))))}

if (fact==0){
fact <-0.0001
}

He\_MDIMP\_RIpar\_CorrRI <- He\_MDIMP\_RIpar\_CorrRI\*fact

He\_MDIMP\_RIpar\$Par <- c(He\_MDIMP\_RIpar\_VarRI,He\_MDIMP\_RIpar\_CorrRI)

ggplot(data=He\_MDIMP\_RIpar, aes(x=Dataset, y=Par, fill=Par\_Tipus)) +
geom\_bar(stat="identity", position=position\_dodge())+
scale\_fill\_brewer(palette="Greens") + theme\_minimal() +

```

 labs(title="Comp. Paràmetres ef. aleatori RI",y="Covariància(Var.
RI)") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

ggplot(data=He_MDIMP_RIpar[-grep("He3", He_MDIMP_RIpar$Dataset),],
 aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI",y="Covariància(Var.
RI)") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

```

```

Comentaris:

Dels 2 models semblaria que únicament milloren en aquests 2 paràmetres els mètodes de dades perdudes el cas de He2. Possiblement en el cas He3 es milloraria molt lleugerament el kNN, però no seria molt significatiu.

```

```{r Par. Ef. Aleat So IMP}
#Prenem la correlació entre els punts més propers com a referencia
#Generació de les llistes a mida de models per poder fer la taula de
paràmetres amb el model REML
So2_MDIMP_R_2 <- ConvList(Comp_IS_RI_MDIMP_So2)
So3_MDIMP_R_2 <- ConvList(Comp_IS_RIS_MDIMP_So3)
So_MDIMP_R_2_0 <- list(So2_MDIMP_R_2,So3_MDIMP_R_2,So3_MDIMP_R_2)
So_MDIMP_R_2 <- ConvList(So_MDIMP_R_2_0)

So_MDIMP_RIpar <- data.frame(Dataset =
paste(rep(c(SoVars,"So3(t)'),each=length(Comp_IS_RI_MDIMP_So2)),
rep(names(Comp_IS_RI_MDIMP_So2),(length(SoVars)+1))))
So_MDIMP_RIpar <- rbind(So_MDIMP_RIpar,So_MDIMP_RIpar)

So_MDIMP_RIpar$Par_Tipus <- factor(rep(c("RI Variància","RI
Correlació"),each=(nrow(So_MDIMP_RIpar)/2)),
levels=c("RI Variància","RI
Correlació"))

So_MDIMP_RIpar_VarRI <- c(
 sapply(1:(length(So_MDIMP_R_2)-4),function(B){
 round(as.numeric(VarCorr(So_MDIMP_R_2[[B]])[1]),4)
 }),
 sapply((length(So_MDIMP_R_2)-3):length(So_MDIMP_R_2),function(B){
 round(as.numeric(VarCorr(So_MDIMP_R_2[[B]])[2]),4)
 })
)
So_MDIMP_RIpar_CorrRI <- sapply(1:length(So_MDIMP_R_2),function(B){
 a<-getVarCov(So_MDIMP_R_2[[B]],type="marginal")
 b<-cov2cor(a[[1]])
 return(round(b[1,2],4))
})
```

```

 })

fact <- if(mean(abs(So_MDIMP_RIpar_VarRI)) >=
mean(abs(So_MDIMP_RIpar_CorrRI))){ #Es fa un càcul del factor més
adient per graficar les 2 escales en el gràfic
 10^(round(log10(abs(mean(So_MDIMP_RIpar_VarRI))/abs(mean(So_MDIMP_-
RIpar_CorrRI)))))
} else {
 1/(10^(round(log10(abs(mean(So_MDIMP_RIpar_CorrRI))/abs(mean(So_MD-
IMP_RIpar_VarRI)))))))
}

if (fact==0){
 fact <-0.0001
}

So_MDIMP_RIpar_CorrRI <- So_MDIMP_RIpar_CorrRI*fact

So_MDIMP_RIpar$Par <- c(So_MDIMP_RIpar_VarRI,So_MDIMP_RIpar_CorrRI)

ggplot(data=So_MDIMP_RIpar, aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI",y="Covariància(Var.-
RI)") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

ggplot(data=So_MDIMP_RIpar[-grep("t", So_MDIMP_RIpar$Dataset),]
, aes(x=Dataset, y=Par, fill=Par_Tipus)) +
 geom_bar(stat="identity", position=position_dodge())+
 scale_fill_brewer(palette="Greens") + theme_minimal() +
 labs(title="Comp. Paràmetres ef. aleatori RI",y="Covariància(Var.-
RI)") +
 scale_y_continuous(expand = c(0, 0),sec.axis = sec_axis(~./fact,
name = "Corr.(RI)")) +
 theme(text = element_text(size=10),axis.text.x =
element_text(angle=80,size = 10,hjust=0))

```

```

Dona la impressió que les millores només es produueixen en el factor de correlació al aplicar els mètodes en els 3 casos, millorant respecte al conjunt amb els valors perduts eliminats.

Intervals de Confiança de la predicción de mitges

No és senzill calcular els intervals de confiança de predicción en els models mixtes ja que la variabilitat depèn de més factors a part del factor residual a part de tenir el factor o factors aleatoris. Per duu a terme aquesta tasca dins el temps disponible per l'anàlisi estadístic es segueix les recomanacions de <http://www.remkoduursma.com/post/2017-06-15-bootpredictlme4/> i per fer-ho s'ajusten tots els models amb la funció `lmer`:

```
```{r MD lmer CI pred Ho Bootstrap IMP}
```

```

#A partir de la tècnica bootstrap amb l'estadístic t es pot deduir la
possible distribució i calcular els intervals de confiança aproximats
de la prediccio

set.seed(7982)
lmer_I_RI_MDIMP_Ho2 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
 lmer(Ho2 ~ 1 + (1|Lot), data=Av_DS_MDIMP_list[[p]], REML=T, na.action=na.omit)
})
pred_lmer_I_RI_MDIMP_Ho2 <-
lapply(1:length(lmer_I_RI_MDIMP_Ho2), function(p){
 predict(lmer_I_RI_MDIMP_Ho2[[p]], newdata=data.frame(Lot="Lot 1"),
 se.fit=TRUE, nsim=100)
}).

````{r MD lmer CI pred Ho Bootstrap plots IMP}

pred_lmer_Ho <- data.frame(Dataset =
rep(HoVars, each=length(Av_DS_MDIMP_list)))
pred_lmer_Ho$VP <- rep(names(Av_DS_MDIMP_list), length(HoVars))
pred_lmer_Ho$fit <- c(
  sapply(1:length(pred_lmer_I_RI_MDIMP_Ho2), function(p){
    pred_lmer_I_RI_MDIMP_Ho2[[p]]$fit
  })
)

pred_lmer_Ho$LCI <- c(
  sapply(1:length(pred_lmer_I_RI_MDIMP_Ho2), function(p){
    pred_lmer_I_RI_MDIMP_Ho2[[p]]$ci.fit[1, ]
  })
)

pred_lmer_Ho$HCl <- c(
  sapply(1:length(pred_lmer_I_RI_MDIMP_Ho2), function(p){
    pred_lmer_I_RI_MDIMP_Ho2[[p]]$ci.fit[2, ]
  })
)

ggplot(pred_lmer_Ho, aes(x=VP, y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3) +
  geom_errorbar(aes(ymin=LCI, ymax=HCl), width=.3, size=.7,
                position=position_dodge(0.05)) +
  scale_color_brewer(palette="Pastel1")

```

```

Comentaris:

En aquest sentit sembla que el sistema kNN aconsegueix generar una prediccio molt semblant al model original.

```

````{r MD lmer CI pred He Bootstrap IMP}
#A partir de la tècnica bootstrap amb l'estadístic t es pot deduir la
possible distribució i calcular els intervals de confiança aproximats
de la prediccio. La manera d'ajustar la funció de variància en lmer no
és igual que lme, s'aproxima acotant els weights a partir de la
covariable Temps.
set.seed(7982)
```

```

lmer_I_RI_W_MDIMP_He2 <- lapply(1:length(Av_DS_MDIMP_list), function(p)
{
  lmer(He2 ~ 1 + (1|Lot), data=Av_DS_MDIMP_list[[p]],
    weights = Temps, REML=T, na.action=na.omit)
})
pred_lmer_I_RI_W_MDIMP_He2
lapply(1:length(lmer_I_RI_W_MDIMP_He2), function(p){
  predict(lmer_I_RI_W_MDIMP_He2[[p]], newdata=data.frame(Lot="Lot 1",
  Temps = 24), se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_I_RI_W_MDIMP_He3 <- lapply(1:length(Av_DS_MDIMP_list), function(p)
{
  lmer(He3 ~ 1 + (1|Lot), data=Av_DS_MDIMP_list[[p]],
    weights = Temps, REML=T, na.action=na.omit)
})
pred_lmer_I_RI_W_MDIMP_He3
lapply(1:length(lmer_I_RI_W_MDIMP_He3), function(p){
  predict(lmer_I_RI_W_MDIMP_He3[[p]], newdata=data.frame(Lot="Lot 1",
  Temps = 24), se.fit=TRUE, nsim=100)
}).

````{r MD lmer CI pred He Bootstrap plots IMP}

pred_lmer_He <- data.frame(Dataset =
rep(HeVars, each=length(Av_DS_MDIMP_list)))
pred_lmer_He$VP <- rep(names(Av_DS_MDIMP_list), length(HeVars))
pred_lmer_He$fit <- c(
 sapply(1:length(pred_lmer_I_RI_W_MDIMP_He2), function(p){
 pred_lmer_I_RI_W_MDIMP_He2[[p]]$fit
 }),
 sapply(1:length(pred_lmer_I_RI_W_MDIMP_He3), function(p){
 pred_lmer_I_RI_W_MDIMP_He3[[p]]$fit
 })
)

pred_lmer_He$LCI <- c(
 sapply(1:length(pred_lmer_I_RI_W_MDIMP_He2), function(p){
 pred_lmer_I_RI_W_MDIMP_He2[[p]]$ci.fit[1,]
 }),
 sapply(1:length(pred_lmer_I_RI_W_MDIMP_He3), function(p){
 pred_lmer_I_RI_W_MDIMP_He3[[p]]$ci.fit[1,]
 })
)

pred_lmer_He$HCI <- c(
 sapply(1:length(pred_lmer_I_RI_W_MDIMP_He2), function(p){
 pred_lmer_I_RI_W_MDIMP_He2[[p]]$ci.fit[2,]
 }),
 sapply(1:length(pred_lmer_I_RI_W_MDIMP_He3), function(p){
 pred_lmer_I_RI_W_MDIMP_He3[[p]]$ci.fit[2,]
 })
)

p2<-ggplot(pred_lmer_He[pred_lmer_He$Dataset=="He2",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
 geom_line() +
 geom_point(size=3) +
 geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3, size=.7,

```

```

position=position_dodge(0.05))

p3<-ggplot(pred_lmer_He[pred_lmer_He$Dataset=="He3",], aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
 geom_line() +
 geom_point(size=3) +
 geom_errorbar(aes(ymin=LCI, ymax=HCI), width=.3, size=.7,
 position=position_dodge(0.05))

grid.arrange(p2,p3)

```

```

Comentaris:

Tot i no haver molta diferència amb el conjunt amb eliminació de valors perduts, possiblement en aquest aspecte el mètode BSR ha estat el mètode més proper al dataset original.

```

```{r MD lmer CI pred So Bootstrap IMP}
#A partir de la tècnica bootstrap amb l'estadístic t es pot deduir la
possible distribució i calcular els intervals de confiança aproximats
de la prediccio.
set.seed(7982)
lmer_IS_RI_MDIMP_So2 <- lapply(1:length(Av_DS_MDIMP_list), function(p){
 lmer(So2 ~ 1 + Temps + (1|Lot), data=Av_DS_MDIMP_list[[p]],
 REML=T,na.action=na.omit)
})
pred_lmer_IS_RI_MDIMP_So2 <-
lapply(1:length(lmer_IS_RI_MDIMP_So2), function(p){
 predict(lmer_IS_RI_MDIMP_So2[[p]], newdata=data.frame(Lot="Lot 1",
 Temps = 24), se.fit=TRUE, nsim=100)
})

set.seed(7982)
lmer_IS_RIS_MDIMP_So3 <- lapply(1:length(Av_DS_MDIMP_list), function(p)
{
 lmer(So3 ~ 1 + Temps + (1+Temps|Lot), data=Av_DS_MDIMP_list[[p]],
 REML=T,na.action=na.omit,control = lmerControl(optimizer
="Nelder_Mead"))
})
pred_lmer_IS_RIS_MDIMP_So3 <-
lapply(1:length(lmer_IS_RIS_MDIMP_So3), function(p){
 predict(lmer_IS_RIS_MDIMP_So3[[p]], newdata=data.frame(Lot="Lot 1",
 Temps = 24), se.fit=TRUE, nsim=100)
})

```{r MD lmer CI pred So Bootstrap plots IMP}

pred_lmer_So          <- data.frame(Dataset      =
rep(SoVars,each=length(Av_DS_MDIMP_list)))
pred_lmer_So$VP <- rep(names(Av_DS_MDIMP_list),length(SoVars))
pred_lmer_So$fit <- c(
  sapply(1:length(pred_lmer_IS_RI_MDIMP_So2), function(p){
    pred_lmer_IS_RI_MDIMP_So2[[p]]$fit
  }),
  sapply(1:length(pred_lmer_IS_RIS_MDIMP_So3), function(p){
    pred_lmer_IS_RIS_MDIMP_So3[[p]]$fit
  })
)
```

```

)
pred_lmer_So$LCI <- c(
  sapply(1:length(pred_lmer_IS_RI_MDIMP_So2), function(p){
    pred_lmer_IS_RI_MDIMP_So2[[p]]$ci.fit[1,]
  }),
  sapply(1:length(pred_lmer_IS_RIS_MDIMP_So3), function(p){
    pred_lmer_IS_RIS_MDIMP_So3[[p]]$ci.fit[1,]
  })
)
pred_lmer_So$HCl <- c(
  sapply(1:length(pred_lmer_IS_RI_MDIMP_So2), function(p){
    pred_lmer_IS_RI_MDIMP_So2[[p]]$ci.fit[2,]
  }),
  sapply(1:length(pred_lmer_IS_RIS_MDIMP_So3), function(p){
    pred_lmer_IS_RIS_MDIMP_So3[[p]]$ci.fit[2,]
  })
)
p2<-ggplot(pred_lmer_So[pred_lmer_So$Dataset=="So2",],           aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3) +
  geom_errorbar(aes(ymin=LCI, ymax=HCl), width=.3, size=.7,
                position=position_dodge(0.05))

p3<-ggplot(pred_lmer_So[pred_lmer_So$Dataset=="So3",],           aes(x=VP,
y=fit, group=Dataset, color=Dataset)) +
  geom_line() +
  geom_point(size=3) +
  geom_errorbar(aes(ymin=LCI, ymax=HCl), width=.3, size=.7,
                position=position_dodge(0.05))

grid.arrange(p2,p3)

```
Realment no es pot apreciar una millora significativa en aquest aspecte pels dos conjunts corregits en front el que ha eliminat els valors perduts, inclús potser estan més allunyats que el conjunt original.

```