

OPENCOURSEWARE
APRENDIZAJE AUTOMÁTICO PARA EL ANÁLISIS DE DATOS
GRADO EN ESTADÍSTICA Y EMPRESA
Ricardo Aler



AjusteHiperSVM

Ricardo Aler

1/8/2019

Ajuste hiper-parámetros SVMs

```
library(mlr)
```

```
## Warning: package 'mlr' was built under R version 3.5.3
```

```
## Loading required package: ParamHelpers
```

```
## Warning: package 'ParamHelpers' was built under R version 3.5.3
```

```
library(mlbench)
```

```
library(mlrHyperopt) # Esta librería ayuda en la obtención de hiper-parámetros
```

```
library(ggplot2) # Librería para hacer plots
```

```
# Esto es para que no haya demasiados mensajes de información en el documento
```

```
configureMlr(show.info = FALSE)
```

```
data(BostonHousing)
```

```
# Primero, definimos una tarea de regresión, cuyos datos están contenidos en el data.frame BostonHousing
```

```
task_bh <- makeRegrTask(data= BostonHousing, target="medv")
```

```
# Segundo, definimos el nombre del algoritmo de aprendizaje ("learner").
```

```
learner_name <- "regr.svm"
```

```
# Tercero, vemos que hiper-parámetros ajustables tiene
```

```
filterParams(getParamSet(learner_name), tunable = TRUE)
```

```
##           Type len      Def
## type      discrete - eps-regression
## kernel    discrete -      radial
## degree    integer  -          3
## gamma     numeric  -          -
## coef0     numeric  -          0
## cost      numeric  -          1
## nu        numeric  -         0.5
## cachesize numeric  -          40
## tolerance numeric  -         0.001
## epsilon   numeric  -          -
## shrinking logical   -          TRUE
## scale     logicalvector <NA>    TRUE
##
##           Constr Req Tunable Trafo
## type      eps-regression,nu-regression - TRUE -
## kernel    linear,polynomial,radial,sigmoid - TRUE -
## degree    1 to Inf Y TRUE -
## gamma     0 to Inf Y TRUE -
## coef0     -Inf to Inf Y TRUE -
## cost      0 to Inf Y TRUE -
## nu        -Inf to Inf Y TRUE -
```

```
## cachesize          -Inf to Inf  -   TRUE  -
## tolerance          0 to Inf   -   TRUE  -
## epsilon            0 to Inf   Y   TRUE  -
## shrinking          -         -   TRUE  -
## scale              -         -   TRUE  -
```

Nuestro learner inicial va a ser una SVM con kernel gaussiano (radial). Lo definimos así:

```
learner_svm <- makeLearner(learner_name, kernel="radial")
```

Vemos que tiene muchos hiper-parámetros, pero sabemos que los más importantes son el **kernel** (linear o radial), el **cost** y **gamma** (que representa la desviación de la gaussiana). Vamos a probar con una radial (gausiana), con lo que ajustaremos sólo **cost** y **gamma**

Es interesante saber que podemos conseguir ayuda sobre el método y de sus parámetros así:

```
helpLearner(learner_name)
```

```
## starting httpd help server ... done
```

```
helpLearnerParam(learner_name, "gamma")
```

```
## *gamma*:
##      Type len Def   Constr Req Tunable Trafo
## 1 numeric -   - 0 to Inf  Y    TRUE   -
## Used: train.
## Requires: kernel != "linear"
## Argument of: e1071::svm
##
## parameter needed for all kernels except linear (default: 1/(data
## dimension))
```

*# Ahora habría que definir un espacio de búsqueda para los hiper-parámetros
Una opción es ir a la página web # <http://mlrhyperopt.jakob-r.de/parconfigs>*

Una segunda opción es descargar directamente el espacio de búsqueda desde la web así:

```
pc = downloadParConfigs(learner.name="regr.svm") # http://mlrhyperopt.jakob-r.de/parconfigs
print(pc)
```

```
## list()
```

```
if(length(pc)>0) {
  ps = getParConfigParSet(pc[[1]], task=task_bh)
  print(ps)
}
```

*# Desgraciadamente, en este caso no hay ninguno exactamente para ese learner
Tendríamos que ir a la página web <http://mlrhyperopt.jakob-r.de/parconfigs>
y buscarlo a mano, para svm.*

En este caso, usaremos una tercera opción, más sencilla: la función **generateParConfig** nos da un espacio de búsqueda básico para un learner concreto.

```
pc_svm <- generateParConfig(learner=learner_name, task=task_bh)
ps_svm <- getParConfigParSet(pc_svm, task=task_bh)
print(ps_svm)
```

```
##      Type len Def   Constr Req Tunable Trafo
## cost numeric -   0 -15 to 15 -   TRUE   Y
```

```
## gamma numeric - -3.7 -15 to 15 - TRUE Y
```

Puede ser interesante ver que función se usa para el **trafo** (transformación), que en ambos casos es 2^x

```
print(ps_svm$pars$cost$trafo)
```

```
## function (x)
## 2^x
## <environment: 0x0000000021b1dc48>
```

```
print(ps_svm$pars$cost$trafo)
```

```
## function (x)
## 2^x
## <environment: 0x0000000021b1dc48>
```

También puede ser interesante saber cómo tendríamos que definir este espacio de búsqueda si hubiera que hacerlo a mano, o quisieramos cambiarlo. Sería así:

```
ps_amano <- makeParamSet(
  makeNumericParam("cost", lower=-15, upper=+15, trafo = function(x) 2^x),
  makeNumericParam("gamma", lower=-15, upper=+15, trafo = function(x) 2^x)
)
```

```
print(ps_amano)
```

```
##           Type len Def      Constr Req Tunable Trafo
## cost  numeric - - -15 to 15 -     TRUE     Y
## gamma numeric - - -15 to 15 -     TRUE     Y
```

Ahora definimos cómo se busca en el espacio de hiper-parámetros (con **randomsearch** en este caso y un **budget** de 100 evaluaciones), y cómo se evalúan los distintos hiper-parámetros (validación cruzada de tres folds).

```
# Ojo, he puesto 1000 evaluaciones para hacer una buena visualización después, pero puede tardar mucho.
# Posiblemente con budget = 50 sea suficiente
```

```
control_grid <- makeTuneControlRandom(budget=1000)
inner_desc <- makeResampleDesc("CV", iter=3)
```

```
# Aquí construimos una secuencia de ajuste seguida de construcción de modelo
```

```
learner_tune_svm <- makeTuneWrapper(learner_svm, resampling = inner_desc, par.set = ps_svm, control = control_grid)
```

```
# También tenemos que definir cómo se va a evaluar el modelo final. En este caso con train/test (holdout)
```

```
outer_desc <- makeResampleDesc("Holdout")
```

```
set.seed(0)
```

```
outer_inst <- makeResampleInstance(outer_desc, task_bh)
```

```
# Por último, usamos resample para entrenar y evaluar learner_tune_svm
```

```
set.seed(0)
```

```
error_tune_svm <- resample(learner_tune_svm, task_bh, outer_inst, measures = list(rmse), extract = getTuneResults)
```

Vemos que los hiper-parámetros que se eligieron en la partición de entrenamiento son los siguientes (también se muestra el error que producen dichos hiper-parámetros en la validación cruzada de 3 folds que se usó para seleccionarlos):

```
error_tune_svm$extract
```

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

```
## Tune result:
## Op. pars: cost=7.41; gamma=0.0626
## rmse.test.rmse=3.7578428
```

y el error del modelo final es:

```
error_tune_svm$aggr
```

```
## rmse.test.rmse
##      3.440738
```

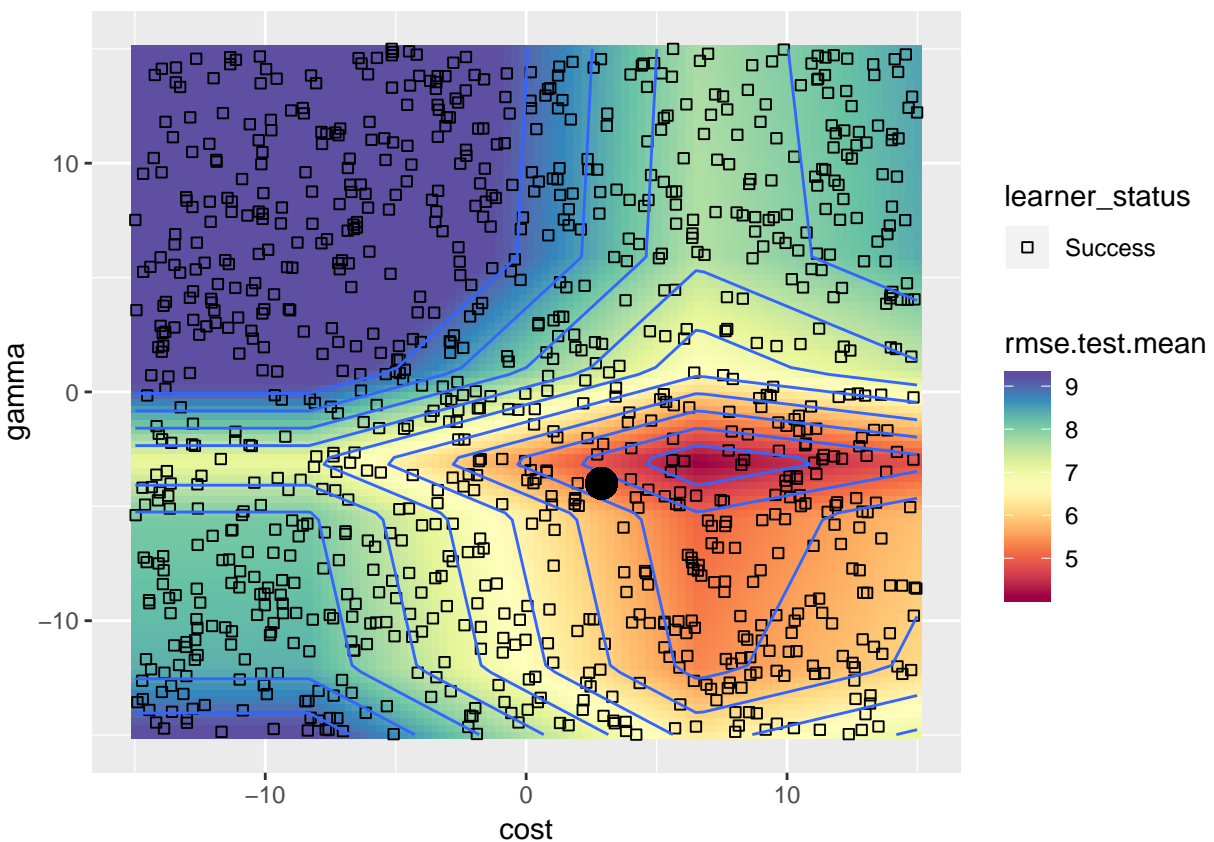
Por último, podemos ver un plot que nos muestra cómo cambia el error con los distintos valores de los hiper-parámetros:

```
data <- generateHyperParsEffectData(error_tune_svm, include.diagnostics = FALSE)
```

```
# Las siguientes dos líneas son para solventar un bug de MLR
names(data$data)[names(data$data)=="rmse.test.rmse"] <- "rmse.test.mean"
data$measures[data$measures=="rmse.test.rmse"] <- "rmse.test.mean"
```


```
plt = plotHyperParsEffect(data, x = "cost", y = "gamma", z = "rmse.test.mean",
  plot.type = "contour", interpolate = "regr.earth", show.experiments = TRUE)
```

```
plot(plt + geom_point(x=log2(error_tune_svm$extract[[1]]$x$cost), y=log2(error_tune_svm$extract[[1]]$x$
```



A continuación podemos ver como se ha ido reduciendo el error con las iteraciones y parece que con bastantes menos que con Random Search se alcanzan mejores mínimos.

```
plt = plotHyperParsEffect(data, x = "iteration", y = "rmse.test.mean",
  plot.type = "line")
plt
```



Ajuste con model-based optimization

Ahora definimos cómo se busca en el espacio de hiper-parámetros con MBO

```
library(mlrMBO)
```

```
## Loading required package: smooof
```

```
## Loading required package: BBmisc
```

```
##
```

```
## Attaching package: 'BBmisc'
```

```
## The following object is masked from 'package:base':
```

```
##
```

```
## isFALSE
```

```
## Loading required package: checkmate
```

```
# Dedicar 80 iteraciones al ajuste
```

```
control = makeMBOControl()
```

```
control = setMBOControlTermination(control, iters = 80)
```

```
control = setMBOControlInfill(control, crit = makeMBOInfillCritEI())
```

```

control_grid <- makeTuneControlMBO(mbo.control = control)

inner_desc <- makeResampleDesc("CV", iter=3)

# Aquí construimos una secuencia de ajuste seguida de construcción de modelo
learner_tune_svm <- makeTuneWrapper(learner_svm, resampling = inner_desc, par.set = ps_svm, control = control)

# También tenemos que definir cómo se va a evaluar el modelo final. En este caso con train/test (holdout)
outer_desc <- makeResampleDesc("Holdout")
set.seed(0)
outer_inst <- makeResampleInstance(outer_desc, task_bh)

# Por último, usamos resample para entrenar y evaluar learner_tune_svm
set.seed(0)
error_tune_svm <- resample(learner_tune_svm, task_bh, outer_inst, measures = list(rmse), extract = getTuneResults)

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.

```



```
## hit.
## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.
## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.
## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.
## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.
## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.
## Warning in (function (fn, nvars, max = FALSE, pop.size = 1000,
## max.generations = 100, : Stopped because hard maximum generation limit was
## hit.
```

Vemos que los hiper-parámetros que se eligieron en la partición de entrenamiento son los siguientes (también se muestra el error que producen dichos hiper-parámetros en la validación cruzada de 3 folds que se usó para seleccionarlos):

```
error_tune_svm$extract
```

```
## [[1]]
## Tune result:
## Op. pars: cost=14.4; gamma=0.0833
## rmse.test.rmse=3.7512245
```

y el error del modelo final es:

```
error_tune_svm$aggr
```

```
## rmse.test.rmse
##      3.405956
```


Por último, podemos ver un plot que nos muestra cómo cambia el error con los distintos valores de los hiper-parámetros. Aquí se ve como la búsqueda se concentra en una buena región (a diferencia de Random Search, que explora todas las zonas por igual).

```
data <- generateHyperParsEffectData(error_tune_svm, include.diagnostics = FALSE)
```

```
# Las siguientes dos líneas son para solventar un bug de MLR
names(data$data)[names(data$data)=="rmse.test.rmse"] <- "rmse.test.mean"
data$measures[data$measures=="rmse.test.rmse"] <- "rmse.test.mean"
```

```
plt = plotHyperParsEffect(data, x = "cost", y = "gamma", z = "rmse.test.mean",
  plot.type = "contour", interpolate = "regr.earth", show.experiments = TRUE)
```

```
plot(plt + geom_point(x=log2(error_tune_svm$extract[[1]]$x$cost), y=log2(error_tune_svm$extract[[1]]$x$
```



A continuación podemos ver como se ha ido reduciendo el error con las iteraciones y parece que con bastantes menos que con Random Search se alcanzan mejores mínimos.

```
plt = plotHyperParsEffect(data, x = "iteration", y = "rmse.test.mean",
  plot.type = "line")
plt
```

