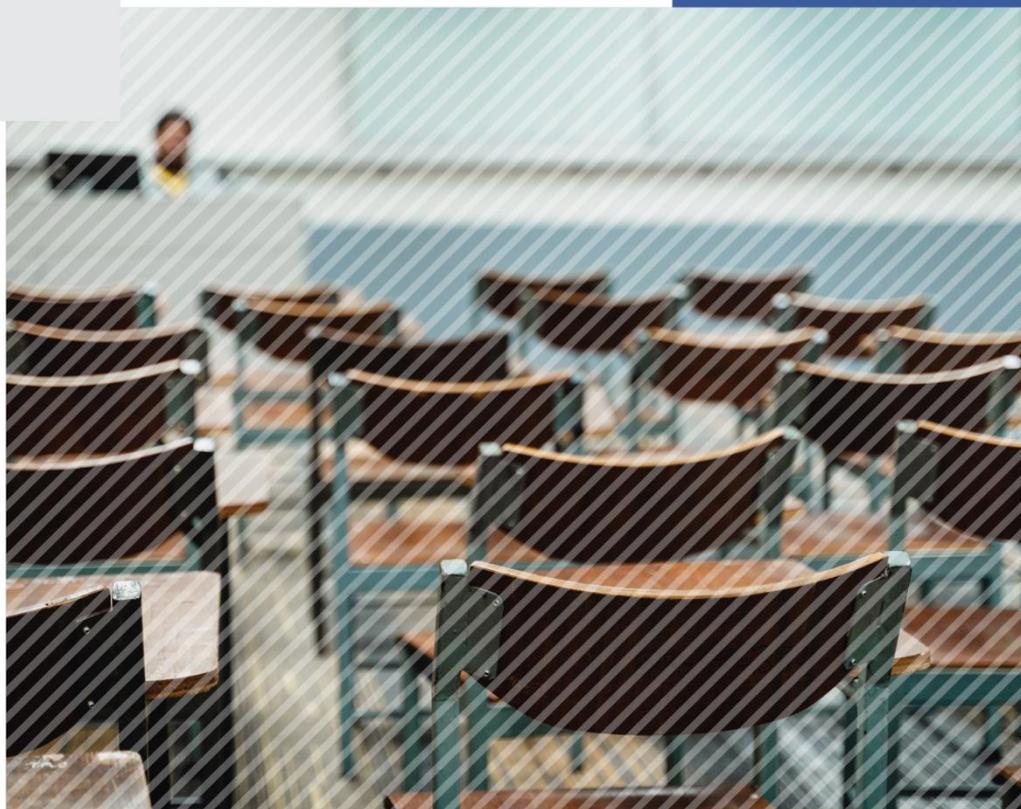


GOVERNO DO ESTADO DO ESPÍRITO SANTO  
SECRETARIA DE ECONOMIA E PLANEJAMENTO – SEP  
INSTITUTO JONES DOS SANTOS NEVES – IJSN

MANUAL



# Preditor do Abandono Escolar

*Manual do pacote em R  
PreditorIJSN*



Instituto Jones  
dos Santos Neves



GOVERNO DO ESTADO  
DO ESPÍRITO SANTO

Outubro de 2023

**GOVERNO DO ESTADO DO ESPÍRITO SANTO**

José Renato Casagrande

**VICE-GOVERNADORIA**

Ricardo Ferraço

**SECRETARIA DE ECONOMIA E PLANEJAMENTO – SEP**

Álvaro Rogério Duboc Fajardo

**INSTITUTO JONES DOS SANTOS NEVES – IJSN**

Diretor Presidente

Pablo Silva Lira

Diretoria de Estudos e Pesquisas

Pablo Medeiros Jabor

Diretoria de Integração e Projetos Especiais

Antonio Ricardo Freislebem da Rocha

Diretoria de Gestão Administrativa

Katia Cesconeto de Paula

Coordenação Geral

Kiara de Deus Demura

Elaboração

Guilherme Armando de Almeida Pereira (Bolsista Fapes)

Kiara de Deus Demura



## Sumário

|  |   |
|--|---|
| 1. Introdução .....                            | 4 |
| 2. Instalação.....                             | 4 |
| 3. Como organizar os seus bancos de dados..... | 6 |
| 4. Exemplo .....                               | 7 |
| 5. Como citar.....                             | 8 |
| Referências .....                              | 8 |



## 1. Introdução

O objetivo deste documento é apresentar as principais funcionalidades do preditor do abandono escolar da rede estadual do Espírito Santo (**PreditorIJSN**). Esse pacote desenvolvido em R é um produto da parceria entre Instituto Jones dos Santos Neves (IJSN), Secretaria de Estado da Educação (SEDU) e Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) – Estudos Educacionais, a fim de auxiliar a gestão da SEDU na prevenção ao abandono escolar.

As descrições dos modelos inseridos no pacote estão disponíveis no Relatório – Preditor de Abandono Escolar (PEREIRA; DEMURA, 2023), bem como nas referências deste documento. Nossa ferramenta utiliza como suporte os pacotes *caret* (2022), *tidyverse* (2019), *ROCR* (2003), *performanceEstimation* (2022) e *ggpubr* (2000).

A principal atualização desta versão diz respeito à inclusão dos métodos de balanceamento da amostra. Recomenda-se, como introdução aos modelos utilizados, as referências Chawla et al. (2002), Hastie, Tibshirani e Friedman (2009), James et al. (2013) e Fernández et al. (2018).

## 2. Instalação

### *Passo 1: Instalando os pacotes auxiliares*

Para que o **PreditorIJSN** funcione corretamente é necessário que o usuário tenha instalado previamente os seguintes pacotes auxiliares em sua máquina: *caret*, *tidyverse*, *ROCR*, *performanceEstimation* e *ggpubr*. Esta ação precisa ser realizada apenas uma única vez.

Para realizar a instalação, execute as seguintes linhas de comando:

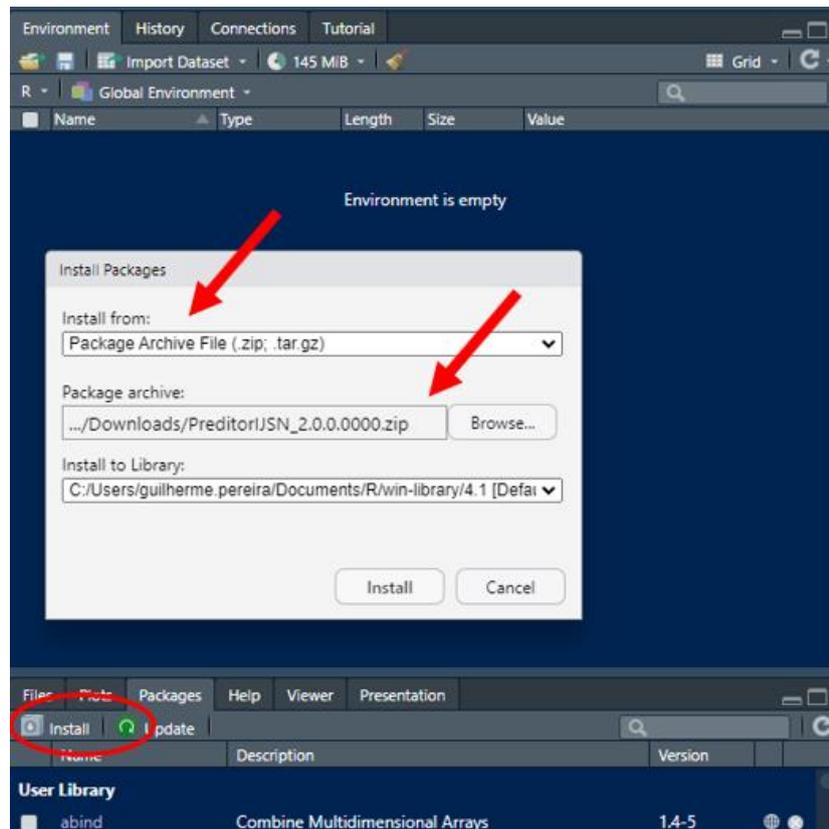
```
#  
install.packages("caret")  
install.packages("tidyverse")  
install.packages("ROCR")  
install.packages("performanceEstimation")  
install.packages("ggpubr")  
#
```

### *Passo 2: Instalando o PreditorIJSN*

Há duas formas de instalar o preditor, considerando a utilização do ambiente de desenvolvimento integrado (*integrated development environment* – IDE) *RStudio*.

A primeira maneira é com o auxílio do *mouse* do computador. Para isso vá em *Install*. Em *Install from*, selecione “Package Archive File (.zip; .tar.gz)”. Por fim, por meio do *Browse* você deve procurar o arquivo do preditor em seu computador. A Figura 1 ilustra esse procedimento.

Figura 1 – Instalando o pacote PreditorIJSN



Elaboração: Estudos Educacionais/IJSN.

A segunda opção utiliza o comando:

```
#  
install.packages("~/Local_do_pacote/PreditorIJSN_2.0.0.0000.zip", repos = NULL, type = "source")  
#
```

Vale a pena observar que o diretório declarado na função `install.packages("~/Local_do_pacote/...")` deve conter o arquivo original do *PreditorIJSN*.

### *Passo 3: Carregando o pacote PreditorIJSN*

Uma vez instalados os pacotes, devemos carregá-los por meio do seguinte comando:

```
#  
library(PreditorIJSN)  
#
```

### 3. Como organizar os seus bancos de dados

O pacote disponibiliza quatro bancos de dados fictícios, sendo dois para o ensino médio e dois para o ensino fundamental. Assim, o usuário pode visualizar como os seus bancos devem ser elaborados. Os bancos presentes no pacote podem ser acessados ao digitar:

```
#  
data(dados2021_EF)  
data(dados2022_EF)  
data(dados2021_EM)  
data(dados2022_EM)  
#
```

Os bancos de dados para a previsão podem conter diversas variáveis, não sendo restritos às variáveis presentes nos bancos ilustrativos. Contudo, algumas especificações devem ser respeitadas:

- (i) As linhas representam os estudantes;
- (ii) As colunas indicam as variáveis;
- (iii) As variáveis devem ser, obrigatoriamente, do tipo *factor* para as variáveis qualitativas e do tipo *numeric* para as variáveis quantitativas;
- (iv) A variável que indica o abandono (quando pertinente) deve ser denominada como *abandono* e possuir o seguinte código: (i) *abandono=1*, corresponde ao abandono; (ii) *abandono=0*, corresponde ao não abandono;
- (v) É mandatário que a variável que identifica o aluno seja nomeada como *CD\_INEP\_ALUNO*;
- (vi) É obrigatória a presença de uma variável denominada *ID\_ETAPA\_MATRICULA*, para indicar a série em análise. Esta é uma variável do tipo *factor* com códigos variando de 1 (1º ano do ensino fundamental) até 9 (9º ano do ensino fundamental). Os níveis dessa variável podem ser alterados de acordo com o interesse do usuário. Caso o banco de dados seja relativo ao ensino médio, esta variável possuirá 3 níveis;
- (vii) É obrigatório que o banco de dados contenha a variável *CD\_INEP\_ESC* indicando o código INEP da escola;
- (viii) É obrigatório que o banco contenha a variável *NOME\_ESCOLA* designando o nome da escola.

Em suma, independentemente do número de variáveis que os bancos de dados possuam, é mandatório que as seguintes variáveis estejam presentes e nomeadas exatamente como apresentadas: *abandono* (apenas para o banco de dados utilizado na previsão), *CD\_INEP\_ALUNO*, *ID\_ETAPA\_MATRICULA*, *CD\_INEP\_ESC* e *NOME\_ESCOLA*.

A Figura 2 ilustra como os bancos devem estar organizados. É recomendado também que não haja dados faltantes (NA) em seus bancos.

Figura 2 – Exemplo de banco de dados

|   | abandono | CD_INEP_ALUNO | ID_ETAPA_MATRICULA | CD_INEP_ESC | NOME_ESCOLA          | IDADE | TP_SEXO | NOTA_ESCOLA_TRI1PT |
|---|----------|---------------|--------------------|-------------|----------------------|-------|---------|--------------------|
| 1 | 1        | 1111          | 6                  | 1750        | Sao Jose             | 19    | F       | 14.21503           |
| 2 | 1        | 1113          | 1                  | 1310        | Maestro Guerra Peixe | 19    | M       | 19.76923           |
| 3 | 1        | 1115          | 4                  | 1860        | Canarinhos           | 19    | M       | 12.77670           |
| 4 | 1        | 1116          | 8                  | 1310        | Maestro Guerra Peixe | 19    | M       | 15.41554           |
| 5 | 1        | 1117          | 5                  | 1860        | Canarinhos           | 23    | F       | 22.60502           |
| 6 | 1        | 1119          | 5                  | 1640        | Ipiranga             | 20    | F       | 18.32938           |
| 7 | 1        | 1121          | 4                  | 1860        | Canarinhos           | 19    | F       | 18.91000           |

Elaboração: Estudos Educacionais/IJSN.

## 4. Exemplo

Pronto! Uma vez instalados e carregados os pacotes, e em posse dos bancos de dados, podemos utilizar o preditor. O pacote desenvolvido possui duas funções principais: uma relativa à previsão para o ensino fundamental (*PreditorEnsinoFundamental*) e a outra à previsão para o ensino médio (*PreditorEnsinoMedio*).

Nesse exemplo vamos estimar o modelo para a 1ª série do ensino médio. Para estimar qualquer modelo você deve ter em suas mãos:

- (i) Banco de dados relativo ao ano que o modelo será estimado. Geralmente utilizamos o ano anterior ao ano que queremos fazer as previsões. Nesse exemplo vamos utilizar `dados_treinamento = dados2021_EM`;
- (ii) Banco de dados relativo ao ano que iremos fazer as previsões. É importante destacar que este banco não contém a variável *abandono*, uma vez que esta será prevista. Neste exemplo vamos utilizar `dados_previsao = dados2022_EM`.

Estimando o modelo e fazendo as previsões:

```
#
model.fit <- PreditorEnsinoMedio(dados_treinamento = dados2021_EM, dados_previsao = dados2022_EM, ETAPA.MATRICULA = 16, TesteValidacao = TRUE, p = 0.8, tipo="lasso", balanceamento = "smote", dir="D:/Local_dos_relatorios/")
#
```

Vale ressaltar que no diretório especificado pelo usuário em `dir="D:/Local_dos_relatorios/"` o pacote irá criar dois arquivos. O primeiro arquivo possui a extensão `.csv` e contém as seguintes informações:

- (i) *Status* - previsão do abandono;
- (ii) *Prob\_Y1* - probabilidade de abandono;
- (iii) *CD\_INEP\_ALUNO* - cód. INEP do aluno;
- (iv) *ID\_ETAPA\_MATRICULA* - indica a série;
- (v) *CD\_INEP\_ESCOLA* - cód. INEP da escola;
- (vi) *NOME\_ESCOLA* - nome da escola.

A Figura 3 apresenta a correspondente saída `.csv`.

Figura 3 – Exemplo da saída `.csv`

| Status | Prob_Y1           | CD_INEP_ALUNO | ID_ETAPA_MATRICULA | CD_INEP_ESC | NOME_ESCOLA          |
|--------|-------------------|---------------|--------------------|-------------|----------------------|
| 1      | 0.57107351922838  | 1347          | 17                 | 1860        | Canarinhos           |
| 1      | 0.568771102872594 | 2160          | 17                 | 1750        | Sao Jose             |
| 0      | 0.44601371809005  | 1206          | 17                 | 1310        | Maestro Guerra Peixe |
| 0      | 0.44295923227065  | 1261          | 17                 | 1420        | Dom Pedro II         |
| 1      | 0.565696600742819 | 2130          | 18                 | 1640        | Ipiranga             |

Elaboração: Estudos Educacionais/IJSN.

O segundo arquivo possui o formato `.pdf` e contém informações sobre a estimação, assim como métricas de desempenho para o conjunto de treinamento.

## 5. Como citar

PEREIRA, Guilherme A. de A.; DEMURA, Kiara de Deus; NUNES, Iago C. PreditorIJSN. R package version 2.0.0.0000. 2023. Disponível em: <https://ijsn.es.gov.br/publicacoes/relatorios/preditor-do-abandono-escolar>. Acesso em: (DATA\_ACESSO).

## Referências

CHAWLA, Nitesh V. et al. SMOTE: synthetic minority over-sampling technique. **Journal of artificial intelligence research**, v. 16, p. 321-357, 2002.



FERNÁNDEZ, Alberto et al. SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary. **Journal of artificial intelligence research**, v. 61, p. 863-905, 2018.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN Jerome. **The elements of statistical learning: data mining, inference and prediction**. New York: Springer series in statistics, 2009.

JAMES, Gareth et al. **An introduction to statistical learning**. New York: Springer, 2013.

KASSAMBARA, A. Ggpubr: 'ggplot2' Based Publication Ready Plots. R package version 0.4.0. 2020. Disponível em: <https://CRAN.R-project.org/package=ggpubr>.

KUHN, M. Caret: Classification and Regression Training. R package version 6.0-82. 2022. Disponível em: <https://CRAN.R-project.org/package=caret>.

SING, T. et al. ROCR: visualizing classifier performance in R. **Bioinformatics**, v. 21, n. 20, p. 3940-3941, 2005. Disponível em: <http://rocr.bioinf.mpi-sb.mpg.de>.

TORGO, Luis. performanceEstimation: An infra-structure for performance estimation and experimental comparison of predictive models in R. R package version 1.1.0. Disponível em: <https://CRAN.R-project.org/package=performanceEstimation>.

WICKHAM et al., (2019). Welcome to the tidyverse. **Journal of Open-Source Software**, v. 4, n. 43, 2019. Disponível em: <https://doi.org/10.21105/joss.01686>.