Acelerando o R com C++

curso-r

Curso-R

Athos Damiani
Curso-R
Bacharel em Estatística

William Amorim
Curso-R
Doutor em Estatística

Fernando Corrêa
Curso-R
Mestrando em Estatística

Julio Trecenti
Curso-R, Terranova, ABJ, Conre
Doutorando em Estatística

Daniel Falbel
Curso-R e RStudio
Bacharel em Estatística

Caio Lente
Curso-R, Terranova, ABJ, Mestrando em ciências da computação

Linha do tempo

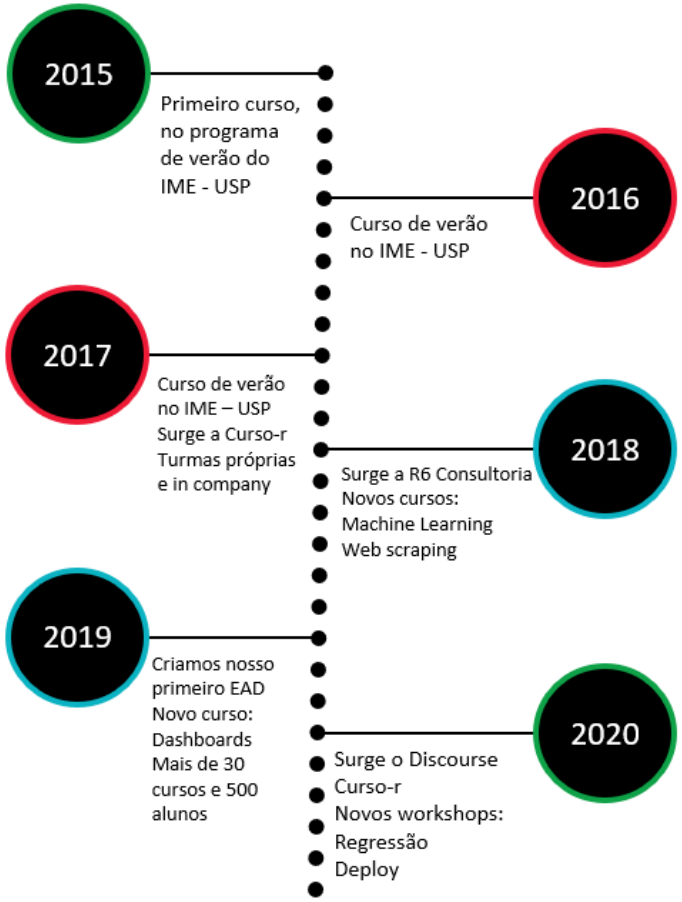

Informações gerais

- As aulas vão das 9h às 13, com uma pausa de 10 min em torno das 11:00
- As aulas serão gravadas e disponibilizadas no Google Classroom
- Podem mandar dúvidas no chat do Zoom ou abrir o microfone para perguntar
- Teremos bastante exercícios para resolver durante o workshop, então se prepare!

Informações de vocês

- Nós gostaríamos de saber sobre vocês:
    - Nome
    - Com o que trabalha?
    - Como imagina usar {Rcpp} no futuro?

Nesse curso vamos falar de

Introdução

- Diferenças entre R e C++
- O que é {Rcpp}?
- Quando usar {Rcpp}?
- Introdução ao {Rcpp}

Intermediário

- Usando matrizes e arrays
- Como interromper loops pelo R
- Casos de uso
- Ponteiros externos (XPtrs)

Miscelânea

- Pacotes com código C++
- Um pouco sobre a API do R em C
- Introdução ao {cpp11}
- Paralelismo com {RcppParallel}

Outros materiais

- Rcpp gallery
- Paper do Rcpp no JSS
- FAQ do Rcpp
- Referência rápida
- Capítulo do Advanced R
- Rcpp for everyone
- Curso na UseR 2020

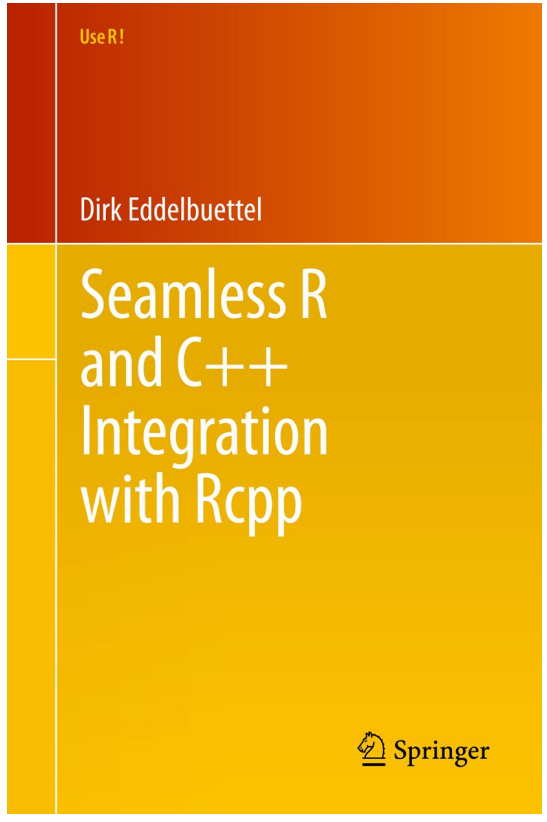

Diferenças entre R e C++

- As duas linguagens tem propósitos bastante diferentes. O R é uma linguagem focada em análise de dados e tem bastante desenvolvimento pensado na interatividade.
- C++ é uma linguagem de mais baixo nível e tem foco em performance e proximidade com a linguagem de máquina. É uma linguagem de propósito muito mais geral.
- Apesar de as duas linguagens possuirem muitos paradigmas diferentes. R tende a ser uma linguagem funcional: em geral escrevemos o que queremos fazer e não o 'como fazer'. C++ é imperativa, o que implica em escrever exatamente o 'como fazer'.

Dito isso, as principais diferenças que precisam ser compreendidas por um programador R aprendendo C++ são:

Diferenças entre R e C++

R

- **interpretada**: existe um interpretador que *parseia* o código e o executa. Esse processo ocorre toda vez que uma linha de código é executada.
- **tipada dinamicamente**: os tipos dos objetos só são verificados na hora da execução do código.

C++

- **(pré) compilada**: o código é compilado, isto é, transformado em linguagem de máquina e depois pode ser executado. Não é necessário nenhum interpretador para executar o código.
- **estaticamente tipada**: durante o processo de compilação verifica-se se os tipos estão corretos. Por exemplo: uma função que retorna um número inteiro só pode retornar um número inteiro.

Diferenças entre R e C++

Além de todas as diferenças conceituais, é claro, as duas linguagens também diferem bastante com relação à sintaxe.

```r
hello ← function(name) {
  print(paste("hello", name))
}
hello("world")
```

```
#> [1] "hello world"
```

```cpp
#include <Rcpp.h>
// [[Rcpp::export]]
void hello (std::string name)
{
  Rcpp::Rcout <<
    "hello " + name <<
      std::endl;
}
```

```r
hello("world")
```

```
#> hello world
```

Rcpp

- O R é escrito principalmente em C (não é C++) e então o R possui uma API em C que permite que você crie extensões.
- A API do R é difícil e exige que você conheça bastante detalhes da linguagem. Além disso, você precisa entender bastante como funciona o *garbage collector* para poder usar corretamente a API em C.
- Rcpp não apenas implementa uma forma de chamar funções do C++ a partir da API do R que é escrita em C, como fornece um conjunto grande de *açúcar sintático* para você não precisar entender tantos detalhes da API C do R.
- O pacote Rcpp é um dos mais utilizados no CRAN e é atualmente a principal ferramenta para criar extensões do R que utilizam C/C++

Quando usar Rcpp?

Existem dois principais motivos para usar Rcpp:

- Você um código lento em R (geralmente envolvendo loops) que não é trivial de vetorizar. Seu objetivo então, é escrever esse código em C++ para se beneficiar da velocidade, sem necessariamente precisar mudar o algoritmo.

Essa é talvez a forma mais comum de se usar Rcpp. Você escreve seu código em R, e otimiza as partes que são *funis* de performance em C++. Pacotes como {text2vec}, {ranger}, {tm} e versões anteriores do {dplyr} usam Rcpp desta forma.

- Você deseja usar, pelo R, uma biblioteca já consolidada escrita em C++. Por exemplo, a libmagick é uma biblioteca escrita em C++ que possui diversas funções para manipulação de imagens - ao invés de re-escrever a sua funcionalidade em R, usamos Rcpp para *conectá-la* ao R.

Pacotes como {magick}, {hunspell}, {haven}, {opencv} e etc. usam Rcpp desta forma.

Ambiente de desenvolvimento

Linux

- Instalar o r-base-dev: rodar sudo apt-get install r-base-dev.

Mac

- Instalar o Xcode Command Line Tools. Rodar: xcode-select --install no terminal.

Windows

- Instalar o RTools: o RTools junta um compilador (MinGW) de código C++, um compilador de Latex e outras ferramentas úteis.

Arquivos do tipo .cpp

O RStudio possui suporte para aquivos do tipo .cpp e vamos usá-lo como IDE.

- Você pode usar a função Rcpp::sourceCpp() para compilar um arquivo .cpp a partir do R.
- É possível usar a função Rcpp::cppFunction() para escrever os códigos em scripts .R
- O RMarkdown permite programar nas duas linguagens, além de Markdown tradicional
- Vamos usar arquivos .cpp puros com comentários que permitem programar em R

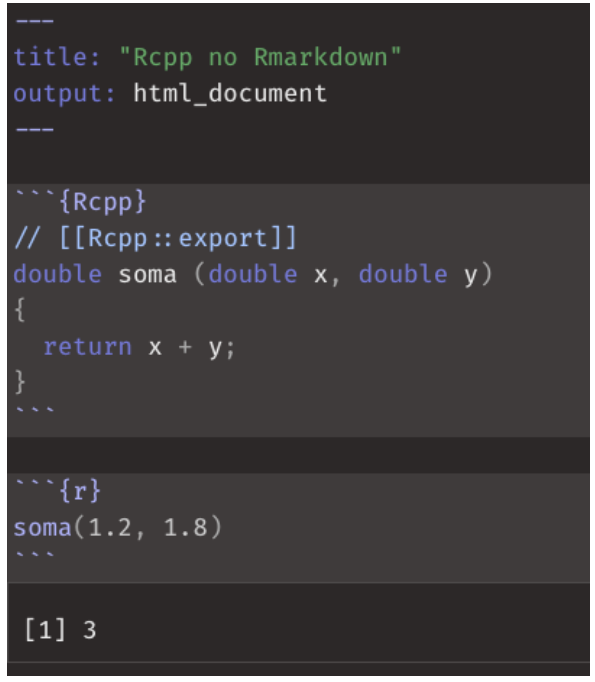

````
---
title: "Rcpp no Rmarkdown"
output: html_document
---

```{Rcpp}
// [[Rcpp::export]]
double soma (double x, double y)
{
  return x + y;
}
```

```{r}
soma(1.2, 1.8)
```

[1] 3
````

Introdução ao Rcpp

O esquema abaixo apresenta o esqueleto de uma função C++. Preste bastante atenção na declaração dos tipos dos objetos (tanto argumentos, quanto variáveis), na especificação do tipo da saída, no ponto-e-vírgula depois de absolutamente todas as linhas e no fato de que return é obrigatório (apesar de nem ser uma função como no R).

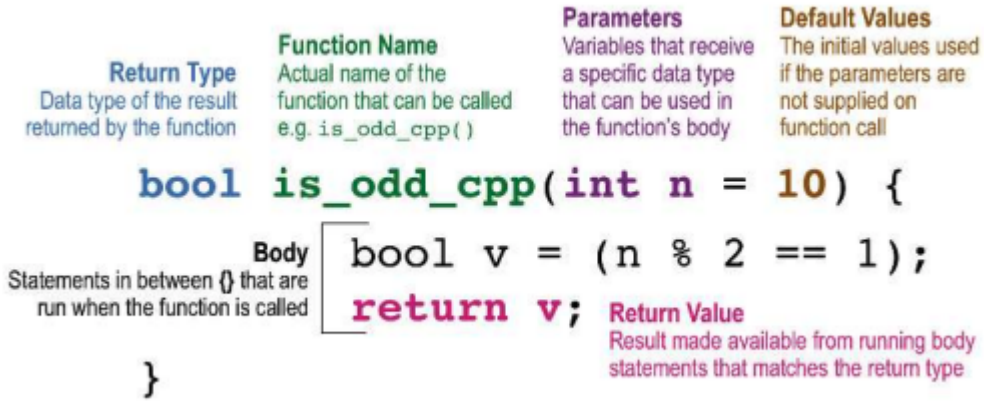

Fonte: *Extending R with C++: A Brief Introduction to Rcpp*

Exemplo 00

Exemplo 01

Exercício 01

Vetores

Assim como o resto dos objetos do C++, vetores precisam ter seus tipos especificados no momento de criação. Felizmente, há tipos específicos que podemos usar sem ter muito trabalho. Aqui falaremos sobre NumericVector, StringVector e LogicalVector.

```
NumericVector v(n);
NumericVector v(n, k);
NumericVector v = NumericVector::create(Named("x") = 1, _["y"] = 2);
```

```
StringVector v(n);
StringVector v(n, c);
StringVector v = StringVector::create(Named("x") = 'a', _["y"] = 'b');
```

Redimensionar vetores não é uma tarefa fácil! Muitas vezes o jeito mais simples é copiar o vetor para um "esqueleto" vazio maior.

Acessar elementos

Acessar elementos de vetores é tão simples quanto no R. Podemos usar tanto [] quanto (): o primeiro ignora acessos fora dos limites e o segundo retorna um erro. Ambos aceitam números (índices), strings (nomes) ou booleanos.

Atribuições funcionam exatamente da mesma forma que o R. **Note que os índices sempre começam em 0!**

```
double x1          = v[n];
double x2          = v[c];
NumericVector res1 = v[numeric];
NumericVector res2 = v[integer];
NumericVector res3 = v[character];
NumericVector res4 = v[logical];
```

```
v[n]         = x1;
v[c]         = x2;
v[numeric]   = v2;
v[integer]   = v2;
v[character] = v2;
v[logical]   = v2;
```

Atributos

Funções membras (também conhecidas como "métodos") são funções que pertencem a um objeto, ou seja, para qualquer objeto de um dado tipo, você pode chamar as suas funções membras com a sintaxe v.f(). Isso é comum no Python, mas apenas pacotes que usam {R6} no R têm métodos.

Função	Descrição
length()/size()	Comprimento do vetor
names()	Nomes do vetor
fill(x)	Preencher o vetor com valor x
sort()	Ordenar o vetor
begin()/end()	Iteradores para o começo e o fim do vetor
push_back(x)/push_front(x)	Colocar o valor x no fim/início do vetor

Exemplo 02

Exercício 02

Exercício 03

NA, NaN, Inf & NULL

Dependendo do tipo do vetor que você está usando você vai precisar usar diferentes símbolos para NA. Isso é consequência direta do fato do C++ ser forte e estaticamente tipada: não podemos criar um vetor sem declarar seu tipo e nem trocar o tipo de um vetor sem declarar a conversão.

Vetor	Símbolo do NA
NumericVector	NA_REAL
IntegerVector	NA_INTEGER
LogicalVector	NA_LOGICAL
CharacterVector	NA_STRING

Para Inf, -Inf e NaN usamos os símbolos: R_PosInf, R_NegInf e R_NaN respectivamente.

Para NULL usamos R_NilValue.

Exemplo 03

Exercício 04

Exercício 05

Fluxo de controle

O fluxo de controle do C++ é praticamente idêntico ao do R, com algumas pequenas diferenças no for.

```
if (x > 0)
  Rcout << "positivo" << std::endl;
else if (x < 0)
  Rcout << "negativo" << std::endl;
else
  Rcout << "zero" << std::endl;
```

Chaves são necessárias se o corpo de uma condição tiver mais de uma linha, assim como no R também!

```
int n = 10;
while (n > 0) {
  Rcout << n << ", ";
  n--;
}
Rcout << "liftoff!" << std::endl;
```

```
for (int n = 10; n > 0; n--) {
  Rcout << n << ", ";
}
Rcout << "liftoff!" << std::endl;
```

Exemplo 04

Exercício 06

Data frames

Para criar um data frame, usamos a função DataFrame::create(), que recebe vetores que servirão como as colunas. A sintaxe é muito parecida com a que vimos até agora para vetores, com uma diferença importante: as colunas serão **referências** aos vetores originais.

```
NumericVector v = {1,2};

// Criando um data frame
DataFrame df = DataFrame::create(Named("V1") = v,
                                 Named("V2") = clone(v));
// Alterando o vetor v
v = v * 2;
```

No código acima, a coluna V1 será multiplicada por 2, enquanto a coluna V2 permanecerá intocada.

Atributos

As funções membras de data frames são muito parecidas com as dos vetores, mas têm algumas distinções importantes. No geral, os métodos operam nas colunas e não nos elementos como acontecia antes com os vetores.

Função	Descrição
length()/size()	Número de colunas
nrows()	Número de linhas
names()	Nomes das colunas
fill(x)	Preencher todas as colunas com valor x
begin()/end()	Iteradores para a primeira/última coluna
push_back(x)/push_front(x)	Colocar o vetor x no fim/início da data frame

Exemplo 05

Exercício 07

RcppArmadillo

{RcppArmadillo} é um pacote de álgebra linear que consegue acelerar *ainda mais* operações com vetores e matrizes. Aqui vamos dar apenas um pequeno exemplo de como ela funciona, mas existem infinitas possibilidades de como usar essa biblioteca.

```
#include <RcppArmadillo.h>
using namespace arma;

vec v;
v.subvec(from, to);                                  // Acesso contíguo

mat M;
M.t()                                                // Matriz transposta
M.reshape()                                          // Redimensionar matrix
M(i, j)                                              // Acessar elemento
inv(M)                                               // Matriz inversa
M.submat(row_from, col_from, row_to, col_to); // Acesso contíguo
```

Exemplo 06

Exercício 08

Chamando funções do R

É possível chamar funções do R pelo Rcpp e, para isso, usamos o tipo Function. Note que é necessário saber exatamente o tipo de saída retornado pela função!

```
#include <Rcpp.h>
using namespace Rcpp;

// [[Rcpp::export]]
NumericVector f1(Function f) {
  return f(1);
}
```

```
f1(function(x) x + 100)
```

```
#> [1] 101
```

Programar em C++ é uma tarefa árdua no começo, mas extremamente recompensadora. Depois de alguns dias batalhando contra erros, sua programação vai ficar consideravelmente mais "defensiva".

```
f1(as.character)
```

```
#> Error in f1(as.character): Not compatible
```

Exemplo 07

Rápido mas perigoso

Já ficou provado que o C++ pode tornar um programa em R exponencialmente mais rápido, mas isso também pode trazer alguns problemas. Um deles é a dificuldade de interromper a execução de um programa! Um loop rodando em {Rcpp} pode ser impossível de parar da mesma forma que faríamos com a tecla ESC em um loop R comum.

```
void forever()
{
  for (int i = 0; true; i++)
  {
    Rcout << "Iteration: " << i << std::endl;
    ::sleep(1);
    Rcpp::checkUserInterrupt();
  }
}
```

Exercício 09