

Analiza danych z badań międzynarodowych za pomocą pakietu intsvy w R

Mateusz Kleczaj (m.kleczaj@ibe.edu.pl)
Jan Szczypiński (j.szczypinski@ibe.edu.pl)

Spis treści

1	Wprowadzenie	2
1.1	Dlaczego warto używać pakietu intsvy?	2
1.2	Ograniczenia pakietu	2
1.3	Obsługiwane badania	3
2	Instalacja pakietu intsvy	3
3	Pobieranie danych	3
3.1	Struktura plików danych	4
3.2	Wczytywanie i łączenie danych	5
4	Funkcje pakietu intsvy	7
4.1	Funkcje analityczne pakietu:	7
5	Przykładowe analizy	8
5.1	Średnie	8
5.2	Tabela rozkładów częstości płci	8
5.3	Regresja liniowa	9
5.4	Regresja logistyczna	9
5.5	Percentyle	10
5.6	Obliczanie odsetka uczniów na każdym z poziomów umiejętności	10
6	Prezentacja graficzna	11
6.1	Średnie	12
6.2	Regresje	13
6.3	Częstości	14
7	Podsumowanie	15

1 Wprowadzenie

Pakiet `intsvy` w R to narzędzie stworzone m.in. dla analityków, naukowców i studentów zajmujących się międzynarodowymi badaniami edukacyjnymi: PISA, PIAAC, TIMSS, PIRLS oraz ICILS. Upraszcza ono analizę dużych zbiorów danych, automatycznie uwzględniając metodologię badań OECD i IEA, taką jak wagi statystyczne, wagi replikacyjne czy wartości prawdopodobne (*plausible values*, PVs). Dzięki `intsvy` można szybko obliczać statystyki, takie jak średnie, procenty, percentyle czy współczynniki regresji, oraz przedstawiać wyniki w formie graficznej.

Dodatkowe zasoby

- [Pełna dokumentacja](#)
- [Dokumentacja CRAN](#)
- [Filmy instruktażowe](#)
- [Przykłady wykorzystania](#)

1.1 Dlaczego warto używać pakietu `intsvy`?

- **Automatyzacja:** upraszcza przetwarzanie złożonych danych, eliminując konieczność ręcznego uwzględniania wag i replikacji
- **Dostępność:** ma łatwo dostępne funkcje do analizy i wizualizacji danych
- **Elastyczność:** obsługuje dane z wielu badań edukacyjnych

1.2 Ograniczenia pakietu

Ważne ograniczenia

Pakiet `intsvy` obsługuje tylko część międzynarodowych badań edukacyjnych. Ponadto nie wspiera modeli wielopoziomowych (np. HLM) ani zaawansowanej analizy korelacji. W celu wykonania takich analiz warto rozważyć użycie innych pakietów, takich jak:

- `lme4` do modeli wielopoziomowych
- `psych` do analizy korelacji
- `EdSurvey` oferuje wsparcie dla szerszego zakresu badań międzynarodowych

Niektóre funkcje pakietu `intsvy` jak np. `select.merge` działają tylko na plikach o rozszerzeniu `.sav`

1.3 Obsługiwane badania

Badanie / Organizacja	Obsługa w pakiecie (<i>intsvy</i>)
TIMSS (IEA)	•
PIRLS (IEA)	•
ICILS (IEA)	•
ICCS (IEA)	×
PIAAC (OECD)	•
PISA (OECD)	•
TALIS (OECD)	×
SSES (OECD)	×

2 Instalacja pakietu *intsvy*

Pakiet *intsvy* instaluje się i ładuje do środowiska R za pomocą komend:

```
install.packages("intsvy")  
library(intsvy)
```

Do obsługi plików *.sav* (SPSS) wymagany jest dodatkowy pakiet *np.haven*.

```
install.packages("haven")  
library(haven)
```

3 Pobieranie danych

Dane i dokumentacja z badań dostępne są na poniższych stronach:

- **PISA:** www.oecd.org/pisa/data
- **TIMSS:** www.iea.nl/data-tools/repository/timss
- **PIRLS:** www.iea.nl/data-tools/repository/pirls
- **ICILS:** www.iea.nl/data-tools/repository/icils
- **PIAAC:** www.oecd.org/skills/piaac/data

Aby korzystać z wszystkich funkcjonalności pakietu *intsvy*, najlepiej pobrać dane w formacie *.sav* (SPSS) ze stron odpowiednich badań.

3.1 Struktura plików danych

Przed rozpoczęciem analizy dane z badań międzynarodowych muszą zostać zaimportowane do środowiska R, co wymaga zrozumienia ich złożonej struktury plików.

3.1.1 Przykład nazewnictwa plików IEA

Zbiory IEA (TIMSS, PIRLS i ICILS) są zazwyczaj podzielone na dużą liczbę plików, pogrupowanych według kraju, poziomu klasy oraz zastosowanego narzędzia badawczego. Po ściągnięciu danych z badania TIMSS 2023 dla klasy 4 w folderze zobaczymy ponad 500 plików.

Przykład nazewnictwa IEA

Przykład: Plik `asapolm8.sav` zawiera dane uczniów z Polski z badania TIMSS 2023 dla klasy 4 w formacie `.sav`

Gdzie:

- `asa`: odpowiedzi na zadania i wyniki uczniów klasy 4
- `pol`: kod kraju (Polska)
- `m8`: cykl badania (TIMSS 2023)

Pierwsza litera w nazwie pliku wskazuje poziom klasy:

- `a` – klasa 4
- `b` – klasa 8

Dalsze litery określają typ danych:

- `asa/bsa` – wyniki uczniów oraz wartości prawdopodobne (PV)
- `asp/bsp` – dane procesowe (np. czasy odpowiedzi)
- `ash` – dane z kwestionariusza rodzica
- `asg/bsg` – dane z kwestionariusza ucznia
- `acg/bcg` – dane z kwestionariusza szkoły
- `atg/btg` – dane z kwestionariusza nauczyciela

3.1.2 Struktura danych PISA

W przypadku badania PISA dane z różnych krajów są połączone w jeden zbiorczy plik (często bardzo duży), bez podziału na osobne pliki krajowe. Pliki są podzielone według cyklu badania oraz typu danych.

Przykład nazewnictwa PISA

Przykład: Plik `CY08MSP_STU_XXX.sav` zawiera dane z kwestionariuszy uczniów z wszystkich krajów z badania realizowanego w roku 2022.

Gdzie:

- CY08 – cykl badania (tu: 2022)
- MSP – Main Study (badanie główne)
- STU_XXX – dane uczniów (student)

Inne oznaczenia:

- SCH_XXX – kwestionariusze szkół
- TCH_XXX – kwestionariusze nauczycieli
- STU_COG – wyniki testów kognitywnych uczniów (czytanie, matematyka itp.)
- STU_FLT – wyniki testów z edukacji finansowej
- STU_ICT – kwestionariusz dotyczący technologii informacyjno-komunikacyjnych
- STU_WBQ – kwestionariusz dobrostanu uczniów

3.2 Wczytywanie i łączenie danych

Pakiet `intsvy` pozwala na szybkie wczytanie i połączenie danych z różnych krajów i źródeł za pomocą funkcji `*.select.merge()`, gdzie `*` to prefiks badania (`timss4g`, `timssg8`, `pisa`, `pirls` lub `intsvy` dla ICILS).

Ważne

Funkcja ta obsługuje tylko pliki w formacie `.sav` (SPSS). Pakiet wymaga wskazania folderu, w którym znajdują się dane oraz zdefiniowania zmiennych, które chcemy połączyć. Wagi replikacyjne i końcowe oraz wartości prawdopodobne (*plausible values*, PV) są dodawane automatycznie. Dla badań IEA tworzona jest także zmienna `IDCNYL` z pełną nazwą kraju.

3.2.1 Dane z badań IEA

```
timss23 <- timssg4.select.merge(  
  folder = "C:/ILSA/TIMSS/T23_Data_SPSS_G4/SPSS Data",  
  countries = c("AUS", "BHR", "ARM", "POL"),  
  student = c("ITSEX", "ASDAGE", "ASBGSLM"),  
  home = c("ASBH01A", "ASBH01K"),  
  school = c("ACBGDAS")  
)
```

W powyższym przykładzie łączymy dane z badania TIMSS 2023. Upewnij się, że ścieżka do folderu z danymi (`folder`) prowadzi do miejsca, w którym zostały zapisane dane pobrane ze strony IEA. Należy pamiętać, że w R ukośnik odwrotny `\` (stosowany w Windows) należy zastąpić ukośnikiem prostym `/`.

Argumenty `countries`, `student`, `home` i `school` pozwalają na wybór konkretnych krajów i zmiennych według rodzaju narzędzia badawczego. W przykładzie wybrano Australię, Bahrajn, Armenię, Polskę oraz zmienne z kwestionariusza ucznia, rodzica i szkoły.

Obiekt `timss23` zawiera wybrane dane z badania TIMSS 2023 wskazane w argumentach `student`, `home` i `school` oraz domyślnie dodawane zmienne, np. wartości prawdopodobne.

Wskazówka

Funkcja `*.var.label` może być użyta przed importem danych w celu przejrzania plików źródłowych i podjęcia decyzji, które kraje i zmienne wybrać.

```
timssg4.var.label(folder = "C:/ILSA/TIMSS/T23_Data_SPSS_G4/SPSS Data")
```

3.2.2 Dane z badań OECD

Sposób wczytywania danych z badania PISA jest podobny, ale wymaga dodatkowo podania nazw plików:

```
pisa22 <- pisa.select.merge(  
  folder = "C:/ILSA/PISA",  
  school.file = "CY08MSP_SCH_QQQ.SAV",  
  student.file = "CY08MSP_STU_QQQ.SAV",  
  student = c("ST250Q02JA", "ESCS", "ST004D01T"),  
  school = c("SC001Q01TA"),  
  countries = c("Australia", "Canada", "Peru", "Poland")  
)
```

i Adnotacja

Dane PIAAC są dostępne w osobnych plikach dla każdego kraju (np. `PRGPOLPUF.sav` dla Polski) i wymagają łączenia w przypadku analiz międzynarodowych. Można to zrealizować za pomocą dowolnej funkcji w R, np. `rbind`.

4 Funkcje pakietu `intsvy`

Funkcje analityczne pakietu mają postać `*.funkcja()`, gdzie `*` to prefiks odpowiadający badaniu (`intsvy` dla ICILS, `pisa`, `timss`, `pirls`, `piaac`).

4.1 Funkcje analityczne pakietu:

Funkcja	Opis
<code>*.mean.pv()</code>	Oblicza średnie dla zmiennych z wartościami prawdopodobnymi (PV), uwzględniając wagi
<code>*.mean()</code>	Oblicza średnie dla zmiennych bez PV, np. danych z kwestionariuszy
<code>*.table()</code>	Tworzy tabele rozkładów dla zmiennych kategorycznych
<code>*.reg.pv()</code>	Przeprowadza regresję liniową z PV
<code>*.reg()</code>	Przeprowadza regresję liniową bez PV
<code>*.log.pv()</code>	Przeprowadza regresję logistyczną z PV
<code>*.log()</code>	Przeprowadza regresję logistyczną bez PV
<code>*.per.pv()</code>	Oblicza percentyle dla zmiennych z PV
<code>*.ben.pv()</code>	Oblicza odsetek uczniów osiągających określone poziomy umiejętności (tzw. benchmarki)

i Adnotacja

Funkcje zwracają obiekty klas (np. `intsvy.mean`, `intsvy.reg`, `intsvy.table`), które można wizualizować za pomocą `plot()`.

5 Przykładowe analizy

Poniższe przykłady pokazano na podstawie wcześniej utworzonych danych z badania TIMSS (timss23) i PISA (pisa22).

5.1 Średnie

```
# Średni wynik z matematyki według kraju i płci w badaniu TIMSS
timss.mean.pv(
  pvlabel = paste0("ASMMAT0", 1:5),
  by = c("IDCNTRYL", "ITSEX"),
  data = timss23
)

# Średni wynik z matematyki według kraju i płci w badaniu PISA
pisa.mean.pv(
  pvlabel = paste0("PV", 1:10, "MATH"),
  by = c("CNT", "ST004D01T"),
  data = pisa22
)
```

5.2 Tabela rozkładów częstości płci

```
# Rozkład częstości płci uczniów w poszczególnych krajach (TIMSS)
timss.table(variable = "ITSEX", by = "IDCNTRYL", data = timss23)

# Rozkład częstości płci uczniów w poszczególnych krajach (PISA)
pisa.table(variable = "ST004D01T", by = "CNT", data = pisa22)
```

5.3 Regresja liniowa

```
# Wpływ płci ucznia i wczesnych aktywności związanych z liczeniem (ASBH01K)
# na wyniki z matematyki w TIMSS
timss.reg.pv(
  pvlabel = paste0("ASMMATO", 1:5),
  by = "IDCNTRYL",
  x = c("ITSEX", "ASBH01K"),
  data = timss23
)

# Wpływ statusu społeczno-ekonomicznego (ESCS) na wyniki z matematyki w PISA
pisa.reg.pv(
  pvlabel = paste0("PV", 1:10, "MATH"),
  by = "CNT",
  x = c("ESCS"),
  data = pisa22
)
```

5.4 Regresja logistyczna

```
# Prawdopodobieństwo osiągnięcia 550 pkt z matematyki w TIMSS na podstawie
# płci i postawy wobec matematyki
timss.log.pv(
  pvlabel = paste0("ASMMATO", 1:5),
  cutoff = 550,
  x = c("ITSEX", "ASBGSLM"),
  by = "IDCNTRYL",
  data = timss23
)

# Prawdopodobieństwo posiadania komputera w domu w zależności od statusu
# społeczno-ekonomicznego (ESCS) w PISA
pisa.log(y = "ST250Q02JA", x = "ESCS", by = "CNT", data = pisa22)
```

5.5 Percentyle

```
# Percentyle osiągnięć matematycznych w TIMSS (np. 5, 25, 50, 75, 95)
timss.per.pv(
  pvlabel = paste0("ASMMATO", 1:5),
  per = c(5, 25, 50, 75, 95),
  by = "IDCNTRYL",
  data = timss23
)

# Percentyle osiągnięć matematycznych w PISA (np. 10, 25, 75, 90)
pisa.per.pv(
  pvlabel = paste0("PV", 1:10, "MATH"),
  per = c(10, 25, 75, 90),
  by = "CNT",
  data = pisa22
)
```

5.6 Obliczanie odsetka uczniów na każdym z poziomów umiejętności

```
# Odsetek uczniów w TIMSS osiągających wyniki równe lub wyższe
# od progów: 400, 475, 550, 625 pkt
timss.ben.pv(
  pvlabel = paste0("ASMMATO", 1:5),
  by = "IDCNTRYL",
  cutoff = c(400, 475, 550, 625),
  data = timss23
)

# Odsetek uczniów w PISA osiągających wyniki równe lub wyższe
# od progów: poziomy 1-6 (355-698 pkt)
pisa.ben.pv(
  pvlabel = paste0("PV", 1:10, "MATH"),
  by = "CNT",
  cutoff = c(355, 407, 480, 553, 626, 698),
  data = pisa22
)
```

6 Prezentacja graficzna

Wyniki analiz przeprowadzonych za pomocą funkcji pakietu `intsvy` (średnich, regresji, rozkładów częstości) można wizualizować za pomocą dedykowanych funkcji `plot()`.


Dodatkowe opcje eksportu

Dodatkowo wyniki można:

- Wyświetlić w konsoli za pomocą funkcji `summary()` z pakietu podstawowego R
 - Eksportować do pliku `.csv`, używając opcji `export = TRUE` w funkcjach analitycznych
- Funkcja `na.omit()` stosowana w przykładach usuwa braki danych z wyników analizy przed ich wizualizacją, co zapobiega błędom w generowaniu wykresów.


6.1 Średnie

```
# Wykres punktowy z przedziałami ufności pokazujący średnie wyniki z matematyki  
# w każdym kraju podziale na płeć (TIMSS)  
plot.intsvy.mean(  
  na.omit(  
    timss.mean.pv(  
      pvlabel = paste0("ASMMATO", 1:5),  
      by = c("IDCNTRYL", "ITSEX"),  
      data = timss23)))
```



6.2 Regresje


```
# Wykres pokazujący związek statusu społeczno-ekonomicznego (ESCS)
# z osiągnięciami uczniów w matematyce w podziale na kraje (PISA)
plot.intsvy.reg(
  na.omit(
    pisa.reg.pv(
      pvlabel = paste0("PV", 1:10, "MATH"),
      x = "ESCS",
      by = "CNT",
      data = pisa22
    )
  )
)
```



6.3 Częstości

```
# Skumulowany wykres słupkowy pokazujący rozkład częstości płci uczniów  
# w każdym z krajów (TIMSS)
```

```
plot.intsvy.table(  
  na.omit(  
    timss.table(  
      variable = "ITSEX",  
      by = "IDCNTRYL",  
      data = timss23  
    )  
  ),  
  stacked = TRUE  
)
```



7 Podsumowanie

Pakiet `intsvy` automatyzuje analizy danych edukacyjnych zawierających wartości prawdopodobne (PVs) oraz wagi replikacyjne, automatycznie dobierając schemat ważenia i obsługując specyfikę danych z międzynarodowych badań edukacyjnych.

! Zalecenia końcowe

1. **Dokumentacja:** Kluczowe jest dokładne zapoznanie się z dokumentacją konkretnego badania, aby prawidłowo określić strukturę danych, nazwy zmiennych oraz odpowiednie funkcje pakietu `intsvy`
2. **Weryfikacja:** Zaleca się weryfikację wyników analiz z oficjalnymi raportami międzynarodowymi lub krajowymi, aby potwierdzić ich poprawność