

Une validation qui tourne sans vous

Transformer les contrôles en une suite qui s'exécute à chaque lecture — un contrat de schéma, trois gravités, un artefact de rapport, et la décision de savoir quels échecs ont le droit d'arrêter la chaîne.

Pierre Robentz Cassion

Leçon 7 sur 8

Nettoyage et validation des données — La trace qui vous survit

Ce que couvre cette leçon

- Les contrôles que vous avez exécutés ne sont pas ceux que vous avez
- Un contrat, pas un script
- Trois gravités, et une seule arrête l'exécution
- Le validateur
- Branchez-le sur la lecture, pas sur une cellule de notebook
- Les constats sont un artefact, comme le profil
- Ce que coûte l'échec bruyant, et pourquoi il reste juste
- La suite

Les contrôles que vous avez exécutés ne sont pas ceux que vous avez

- Six leçons de contrôles, et chacun d'eux a été exécuté par une personne qui a décidé de l'exécuter.

Un contrat, pas un script — En Python (suite)

```
CONTRACT = {
    "name": "muac-screening",
    "key": ["child_id"],
    "columns": {
        "child_id": {"type": "string", "required": True},
        "commune": {"type": "string", "required": True, "allowed": COMMUNES},
        "screening_date": {"type": "date", "required": True,
                           "min": "2024-01-01", "max": "2024-12-31"},
        "age_months": {"type": "integer", "required": False, "min": 6, "max": 59},
        "sex": {"type": "string", "required": True, "allowed": ["f", "m"]},
        "muac_mm": {"type": "integer", "required": False, "min": 80, "max": 220,
                    "sentinels": [-99]},
        "oedema": {"type": "boolean", "required": False},
        "outcome": {"type": "string", "required": True, "allowed": OUTCOMES},
    },
    "expected_rows": (3500, 5000),
```

Un contrat, pas un script — En Python (suite)

```
"max_missing": {"age_months": 0.10, "muac_mm": 0.05},  
}
```

Un contrat, pas un script — En R (suite)

```
CONTRACT <- list(  
  name = "muac-screening",  
  key  = "child_id",  
  columns = list(  
    child_id      = list(type = "character", required = TRUE),  
    commune       = list(type = "character", required = TRUE, allowed = COMMUNES),  
    screening_date = list(type = "Date", required = TRUE,  
                          min = as.Date("2024-01-01"), max = as.Date("2024-12-31")),  
    age_months    = list(type = "integer", required = FALSE, min = 6, max = 59),  
    sex           = list(type = "character", required = TRUE, allowed = c("f", "m")),  
    muac_mm       = list(type = "integer", required = FALSE, min = 80, max = 220,  
                          sentinels = -99),  
    oedema        = list(type = "logical", required = FALSE),  
    outcome       = list(type = "character", required = TRUE, allowed = OUTCOMES)  
  ),  
  expected_rows = c(3500, 5000),
```

Un contrat, pas un script — En R (suite)

```
max_missing = list(age_months = 0.10, muac_mm = 0.05)  
)
```

Un contrat, pas un script

- `expected_rows` — est un intervalle, pas un nombre
- `max_missing` — transforme le constat de la leçon 2 en limite

Trois gravités, et une seule arrête l'exécution

Gravité	Signification	Effet
error	Le fichier n'est pas analysable en l'état	Arrêt. Rien en aval ne s'exécute.
warning	Quelque chose ne va pas sur certaines lignes	Les signaler, continuer, rapporter le compte
note	Bon à savoir, attendu	Rapport seulement

Trois gravités, et une seule arrête l'exécution

- Les erreurs portent sur le fichier. Les avertissements portent sur des lignes — Si vous avez envie de faire d'un...

Le validateur — En Python (suite)

```
from dataclasses import dataclass

@dataclass
class Finding:
    check: str
    severity: str
    count: int
    detail: str

def validate(df, contract):
    findings = []

    missing = set(contract["columns"]) - set(df.columns)
    if missing:
```

Le validateur — En Python (suite)

```
findings.append(Finding("columns-present", "error", len(missing),
                        f"missing columns: {sorted(missing)}"))

return findings                                # nothing else is meaningful

low, high = contract["expected_rows"]
if not low <= len(df) <= high:
    findings.append(Finding("row-count", "error", len(df),
                            f"{len(df)} rows, expected {low}-{high}"))

duplicated = df.duplicated(subset=contract["key"], keep=False)
if duplicated.any():
    findings.append(Finding("key-unique", "error", int(duplicated.sum()),
                            f"rows sharing a {contract['key']}"))

for column, spec in contract["columns"].items():
    values = df[column]
```

Le validateur — En Python (suite)

```
if spec.get("required") and values.isna().any():
    findings.append(Finding(f"{column}-required", "error",
                           int(values.isna().sum()), "required column has blanks"))

if "allowed" in spec:
    unexpected = set(values.dropna().unique()) - set(spec["allowed"])
    if unexpected:
        findings.append(Finding(f"{column}-allowed", "error", len(unexpected),
                                f"unexpected values: {sorted(unexpected)}"))

if "min" in spec:
    out = (values < spec["min"]) | (values > spec["max"])
    if out.any():
        findings.append(Finding(f"{column}-range", "warning", int(out.sum()),
                                f"outside {spec['min']}-{spec['max']}"))

for column, limit in contract["max_missing"].items():
    share = df[column].isna().mean()
```

Le validateur — En Python (suite)

```
    if share > limit:
        findings.append(Finding(f"{column}-missing", "error", int(df[column].isna().sum())
),
                        f"{share:.1%} missing, limit {limit:.0%}")

return findings
```

Le validateur — En R (suite)

```
validate <- function(df, contract) {  
  findings <- list()  
  add <- function(check, severity, count, detail) {  
    findings[[length(findings) + 1]] <-  
      tibble::tibble(check = check, severity = severity, count = count, detail = detail)  
  }  
  
  missing <- setdiff(names(contract$columns), names(df))  
  if (length(missing)) {  
    add("columns-present", "error", length(missing),  
      paste("missing columns:", paste(missing, collapse = ", ")))  
    return(dplyr::bind_rows(findings))  
  }  
  
  if (!dplyr::between(nrow(df), contract$expected_rows[1], contract$expected_rows[2])) {  
    add("row-count", "error", nrow(df), sprintf("%d rows, expected %d-%d", nrow(df),
```

Le validateur — En R (suite)

```
    contract$expected_rows[1], contract$expected_rows[2]))  
  }  
  
dup <- duplicated(df[contract$key]) | duplicated(df[contract$key], fromLast = TRUE)  
if (any(dup)) add("key-unique", "error", sum(dup), "rows sharing a key")  
  
for (column in names(contract$columns)) {  
  spec <- contract$columns[[column]]  
  values <- df[[column]]  
  if (isTRUE(spec$required) && any(is.na(values))) {  
    add(paste0(column, "-required"), "error", sum(is.na(values)), "required column has  
    blanks")  
  }  
  if (!is.null(spec$allowed)) {  
    unexpected <- setdiff(unique(stats::na.omit(values)), spec$allowed)  
    if (length(unexpected)) {  
      add(paste0(column, "-allowed"), "error", length(unexpected),
```

Le validateur — En R (suite)

```
        paste("unexpected values:", paste(unexpected, collapse = ", ")))
    }
}
if (!is.null(spec$min)) {
  out <- values < spec$min | values > spec$max
  if (any(out, na.rm = TRUE)) {
    add(paste0(column, "-range"), "warning", sum(out, na.rm = TRUE),
        sprintf("outside %s-%s", spec$min, spec$max))
  }
}
}

dplyr::bind_rows(findings)
}
```

Branchez-le sur la lecture, pas sur une cellule de notebook — En Python

```
def load_screening(path, contract=CONTRACT):  
    df = read_typed(path, contract)  
    findings = validate(df, contract)  
  
    errors = [f for f in findings if f.severity == "error"]  
    for finding in findings:  
        print(f"[{finding.severity}] {finding.check}: {finding.count} - {finding.detail}")  
  
    if errors:  
        raise ValueError(f"{len(errors)} validation errors in {path}")  
    return df, findings
```

Branchez-le sur la lecture, pas sur une cellule de notebook — En R

```
load_screening <- function(path, contract = CONTRACT) {  
  df <- read_typed(path, contract)  
  findings <- validate(df, contract)  
  
  if (nrow(findings)) print(findings, n = Inf)  
  if (any(findings$severity == "error")) {  
    stop(sprintf("%d validation errors in %s", sum(findings$severity == "error"), path))  
  }  
  list(data = df, findings = findings)  
}
```

Branchez-le sur la lecture, pas sur une cellule de notebook

- Il n'existe désormais aucun moyen de lire ce fichier sans le valider — C'est tout le mécanisme

Les constats sont un artefact, comme le profil — En Python

```
import json
from pathlib import Path

Path("outputs/validation").mkdir(parents=True, exist_ok=True)
Path("outputs/validation/muac-2024-q4.json").write_text(
    json.dumps([f.__dict__ for f in findings], indent=2)
)
```

Les constats sont un artefact, comme le profil — En R

```
jsonlite::write_json(findings,  
  here::here("outputs", "validation", "muac-2024-q4.json"),  
  pretty = TRUE  
)
```

Les constats sont un artefact, comme le profil — En Python

```
history = pd.concat([
    pd.read_json(p).assign(quarter=p.stem)
    for p in sorted(Path("outputs/validation").glob("*.json"))
])
print(history.pivot_table(index="check", columns="quarter", values="count", fill_value=0))
```

Les constats sont un artefact, comme le profil — En R

```
history <- purrr::map_dfr(  
  list.files(here::here("outputs", "validation"), full.names = TRUE),  
  ~ jsonlite::read_json(.x, simplifyVector = TRUE) |>  
    dplyr::mutate(quarter = tools::file_path_sans_ext(basename(.x)))  
)  
  
tidyr::pivot_wider(history, id_cols = check, names_from = quarter, values_from = count)
```

Ce que coûte l'échec bruyant, et pourquoi il reste juste — Exemple

```
[error] commune-allowed: 1 - unexpected values: ['Petite-Riviere']  
[error] age_months-missing: 226 - 5.4% missing, limit 5%  
ValueError: 2 validation errors in muac-screening-2024-q4.csv
```

- La suite trouve désormais tout et ne change rien — à dessein, puisque chaque modification jusqu'ici a été un signalement.

Lire la leçon complète, avec le code exécutable

[https://data-analysis.cassion.dev/fr/cours/data-cleaning-and-validation/
cleaning-07-validation-that-runs](https://data-analysis.cassion.dev/fr/cours/data-cleaning-and-validation/cleaning-07-validation-that-runs)