2.4. Restrições de integridade

Uma base de dados está num estado de integridade se contém apenas dados válidos.

Os dados armazenados devem estar de acordo com a realidade

Empregado (Emp#, Nome, Categoria, Salário , Dep#)

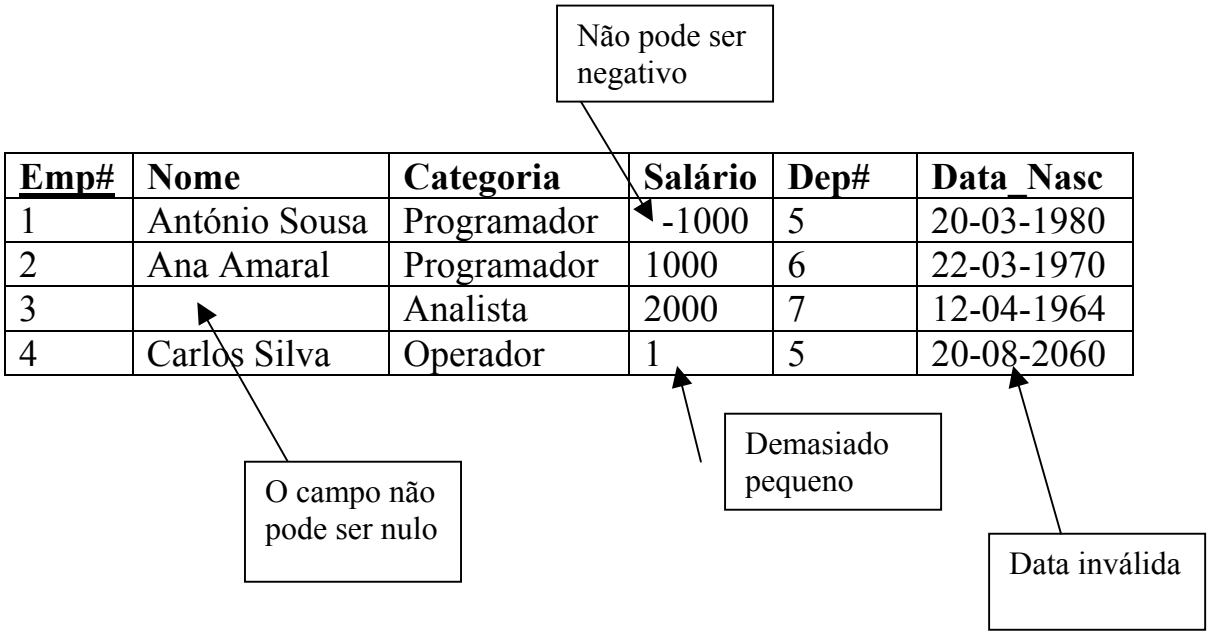

Emp#	**Nome**	**Categoria**	**Salário**	**Dep#**	**Data_Nasc**
1	António Sousa	Programador	-1000	5	20-03-1980
2	Ana Amaral	Programador	1000	6	22-03-1970
3		Analista	2000	7	12-04-1964
4	Carlos Silva	Operador	1	5	20-08-2060

Restrições de integridade são regras, que definem a validade dos dados

Por exemplo, para a relação anterior:

- O campo Nome não pode ser nulo
- O Salário tem que ser superior ao valor do salário mínimo nacional
- A Data de nascimento tem que ser maior que 01-01-1920 e menor que 01-01-2000 !!

. Estas regras vão fazer parte da definição da tabela.

. Quando um dado é inserido, alterado ou apagado o SGBD vai verificar se as regras definidas são respeitadas.

As regras do exemplo anterior denominam-se restrições de

"Integridade de domínio"

São regras que se aplicam aos atributos de uma dada tabela, definindo o domínio de cada atributo.

"Integridade de entidade"

Emp#	**Nome**	**Categoria**	**Salário**	**Dep#**	**Data_Nasc**
1	António Sousa	Programador	1000	5	20-03-1980
2	Ana Amaral	Programador	1000	6	22-03-1970
3	José Costa	Analista	2000	7	12-04-1964
2	Carlos Silva	Operador	500	5	20-08-1980

Um campo que é chave primária não pode ter valores duplicados (nem ter valor nulo)

- Ao declararmos um atributo como chave primária da relação o SGBD não deixa que a relação tenha dois tuplos com o mesmo valor nesse atributo

"Integridade referencial"

Restrição de integridade que relaciona duas relações

Empregado

Emp#	**Nome**	**Categoria**	**Salário**	**Dep#**	**Data_Nasc**
1	António Sousa	Programador	1000	5	20-03-1980
2	Ana Amaral	Programador	1000	6	22-03-1970
3	José Costa	Analista	2000	7	12-04-1964
4	Carlos Silva	Operador	500	5	20-08-1980

Departamento

Dep#	**Nome**	**Local**
5	D1	Lisboa
6	D2	Porto
7	D3	Lisboa

O atributo Dep# na tabela Empregado é chave estrangeira (ou externa) sendo chave primária na tabela Departamento

Se, se indica que Dep# é chave estrangeira da relação Empregado então cada valor do Atributo Dep# na tabela Empregado tem obrigatoriamente que existir na tabela Departamento.

O que acontece quando se tenta apagar na tabela Departamento o Departamento cujo Dep# = 5 ?

- Ou o SGBD não deixa apagar

- Ou apaga o registo e depois apaga na tabela Empregado todos os Empregados cujo número de departamento é 5 (apagamento em cascata)

"Regras de negócio"

Restrições de integridade mais complexas que não podem ser definidas na estrutura da base de dados. São verificadas pelos programas de aplicação.

Exemplos

. O salário de um empregado não pode diminuir, só aumentar

. Um empregado não pode ganhar mais do que o seu chefe

...

3. Teoria da Normalização

Ao modelar a informação procura-se:

. Um modelo que represente fielmente a realidade

. Um modelo capaz de responder às funcionalidades que se pretendem

Queremos obter um modelo com propriedades que garantam:

. Redundância mínima

. Facilidade de Manutenção

. Estabilidade face a futuras alterações

Dados redundantes

EmpregadoDepartamento

NumEmp	Nome	Categoria	Salário	Dep	TelDep	LocalDep
10	**José da Silva**	**Programador**	**2500**	**1**	**213334555**	**Lisboa**
20	**Maria Costa**	**Analista**	**5000**	**2**	**224446888**	**Porto**
30	**João Fonseca**	**Operador**	**600**	**1**	**213334555**	**Lisboa**
40	**Ana Faria**	**Analista**	**5200**	**4**	**275222333**	**Covilhã**

Nesta tabela existem dados redundantes. Os dados de um dado departamento são repetidos para cada empregado desse departamento.

Se apagarmos este número de departamento deixamos de saber qual o departamento do empregado 30.
Dado duplicado mas não redundante

Dados redundantes.
Se apagarmos esta informação continuamos a saber os dados do departamento 1 !!

Relações que têm dados redundantes podem vir a ter anomalias de inserção, eliminação ou modificação.

Anomalias de inserção:

. Para inserir um novo empregado temos que inserir toda a informação do departamento a que pertence tendo o cuidado de não criar inconsistências com a informação já existente.
. Não é possível criar um departamento que ainda não tenha empregados. Note-se que o atributo NumEmp é chave da relação logo o seu valor não pode ser nulo.

Anomalias de eliminação:

. Se eliminarmos um empregado que seja o único empregado de um dado departamento perdemos a informação desse departamento.

Anomalias de modificação:

. Se quisermos alterar um atributo de um dado departamento (por ex. o telefone do dep. 1) temos que actualizar o valor do atributo em todos os empregados que pertencem a esse departamento.

Podemos evitar as anomalias anteriores se decompusermos a relação EmpregadoDepartamento nas relações:

Empregado (NumEmp, Nome, Categoria, Salário, Dep) e

Departamento(Dep, TelDep, LocalDep).

A teoria da normalização, desenvolvida por Edgar Codd no âmbito do modelo relacional, define um processo de estruturar as tabelas de uma base de dados de forma a minimizar a redundância de dados.

A teoria da normalização utiliza o conceito da Dependência Funcional que vamos começar por estudar:

3.1. Dependências Funcionais

Seja a relação:

Morada (Nome, Endereço , Cidade , CodPostal, Telefone)

Assumindo que todos os nomes são diferentes, podemos descrever as seguintes dependências entre os atributos da relação morada:

i) Dado um Nome específico, este determina um único tuplo da relação Morada

(isto é, determina valores únicos para os atributos Endereço, Cidade, CodPostal, Telefone)

ii) Dados valores dos atributos Endereço e Cidade, todos os tuplos da relação Morada com esses valores (se existirem) têm o mesmo valor do atributo CodPostal.

iii) A um determinado valor de CodPostal corresponde um único valor do atributo Cidade.

As associações lógicas descritas entre os atributos da relação Morada são denominadas **dependências lógicas**.

Tipos de dependências lógicas:

. Dependências Funcionais

. Dependências Multivalor (a estudar mais tarde)

. Dependências de Junção (a estudar mais tarde)

(1) Definição de Dependência Funcional (DF)

Seja $R(A_1, A_2, \ldots, A_n)$ um esquema de relação e X e Y subconjuntos de $\{A_1, A_2, \ldots, A_n\}$

Dizemos que existe uma Dependência Funcional entre X e Y e escrevemos $X \rightarrow Y$ *(X determina Y)* sse em qualquer instante *t*, quaisquer tuplos de R com o mesmo valor de X têm necessariamente o mesmo valor de Y.

Diagrama de Dependência Funcional

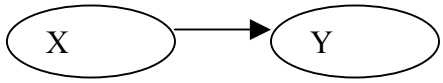

. X determina Y

. Y depende de X

(2) Exemplo

Nome → Endereço

Nome → Cidade

Nome → CodPostal

Nome → Telefone

Endereço , Cidade → CodPostal

CodPostal → Cidade

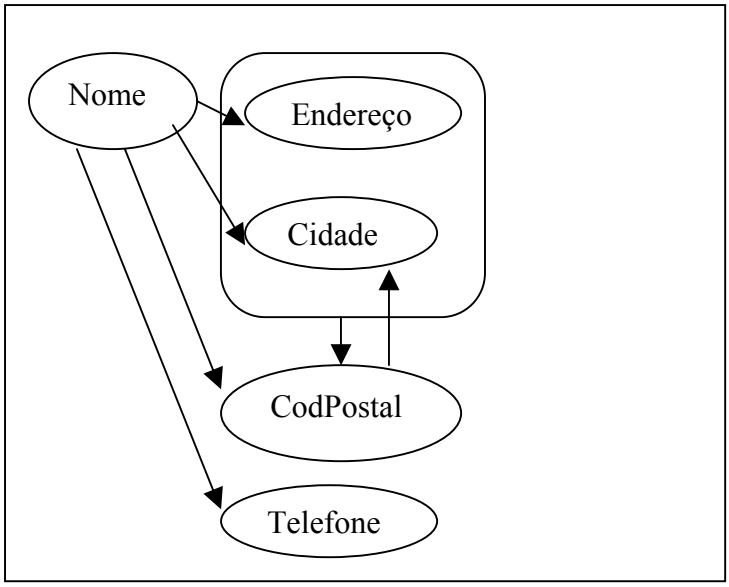

(3) Chave (candidata)

Seja a relação R ($A_1, A_2, \ldots, A_n$) e X um conjunto de atributos de R

($X \subseteq \{ A_1, A_2, \ldots, A_n \}$)

X é chave de R sse

(i) $\forall_i \quad X \rightarrow A_i \quad i = 1,2,\ldots n$

X determina funcionalmente todos os atributos de R

(ii) $\nexists_{y \subset x} \; : \; \forall_i \quad Y \rightarrow A_i \quad i = 1,2,\ldots n$

Não existe um subconjunto de X que determine todos os atributos de R

➔ *Nome é a única chave da relação morada*

(4) Super-chave

Se um conjunto de atributos X satisfaz a condição (1) mas não a (2) é denominado Super-chave da relação.

➔ *Qualquer conjunto de atributos que contenha o atributo Nome é super-chave da relação morada*

(5) Toda a relação tem uma chave

Demonstração:

Dada uma relação R (A_1, A_2, ... , A_n) verifica-se que

$A_1, A_2, \ldots, A_n \rightarrow A_i \quad i = 1,2,\ldots n$

Se não existe um $X \subset \{A_1, A_2, \ldots, A_n\}$ tal que $X \rightarrow A_i$ então

$A_1, A_2, \ldots, A_n$ é a chave de R.

Caso contrário X contém uma chave.

(6) Chave Primária

- É a chave candidata escolhida.

- Nenhuma das suas ocorrências pode ter valor nulo.

(7) Propriedades básicas das DF's

(i) Unicidade

Sejam $f: X \rightarrow Y$ e $g: X \rightarrow Y$, dependências funcionais,

então $f = g$

(ii) Reflexibilidade

Se $X \subseteq Y$ então existe a dependência funcional $Y \rightarrow X$

Dependência Funcional Trivial: todo o conjunto de atributos determina todos os seus subconjuntos.

(iii) Transitividade

Se $X \rightarrow Y$ e $Y \rightarrow Z$ então $X \rightarrow Z$

(iv) União

Se $X \rightarrow Y$ e $X \rightarrow Z$ então $X \rightarrow YZ$

Exemplo:

Voltando à relação Morada,

Morada (Nome, Endereço , Cidade , CodPostal, Telefone).

Vimos que existiam as Df's:

Nome $\rightarrow$ Endereço

Nome → Cidade

Nome → CodPostal

Nome → Telefone

Endereço , Cidade → CodPostal

CodPostal → Cidade

A – Por reflexibilidade,

Endereço , Cidade → Endereço

Endereço , Cidade → Cidade [1]

B – De "Endereço , Cidade → CodPostal" e "CodPostal → Cidade" ,

por transitividade obtemos

Endereço , Cidade → Cidade [2]

C – Pela unicidade [1] e [2] são a mesma dependência funcional.

D – De "Nome → Telefone" e "Nome → Endereço" obtemos por união

Nome → Telefone, Endereço

Por união obtemos também Nome → Cidade, CodPostal

Novamente por união Nome → Telefone, Endereço, Cidade, CodPostal

o que significa que Nome é chave da relação Morada.

(8) Propriedades derivadas das DF's

(i) Distributividade (decomposição)

Se $X \rightarrow YZ$ então $X \rightarrow Y$ e $X \rightarrow Z$

Dem.

$YZ \rightarrow Y$ e $YZ \rightarrow Z$ (por reflexibilidade)

Se $X \rightarrow YZ$ e *$YZ \rightarrow Y$ então por transitividade* $X \rightarrow Y$ q.e.d.[1]

Se $X \rightarrow YZ$ e *$YZ \rightarrow Z$ então por transitividade* $X \rightarrow Z$ q.e.d.

(ii) Aumento

Se $X \rightarrow Y$ e $W \rightarrow Z$ então $XW \rightarrow YZ$

Dem.

$XW \rightarrow X$ (reflexibilidade) e $X \rightarrow Y$ => (por transitividade) $XW \rightarrow Y$

$XW \rightarrow W$ (reflexibilidade) e $W \rightarrow Z$ => (por transitividade) $XW \rightarrow Z$

$XW \rightarrow Y$ e $XW \rightarrow Z$ => (por união) $XW \rightarrow YZ$ q.e.d.

[1] "quod erat demonstrandum"

(iii) Pseudo – transitividade

Se $X \rightarrow Y$ e $YW \rightarrow Z$ então $XW \rightarrow Z$

Dem.

$X \rightarrow Y$ e $W \rightarrow W$ (por reflexibilidade) => (por aumento) $XW \rightarrow YW$

$XW \rightarrow YW$ e $YW \rightarrow Z$ => (por transitividade) $XW \rightarrow Z$

Exemplo:

Aplicando a pseudo-tansitividade às dependências funcionais

Nome $\rightarrow$ Endereço e Endereço, Cidade $\rightarrow$ CodPostal

obtemos Nome, Cidade $\rightarrow$ CodPostal

(9) Perda de informação

Seja a relação

R (Nome, Telefone, Cidade)

em que os atributos Telefone e Cidade não dependem funcionalmente do atributo Nome

Nome $\not\rightarrow$ Telefone

Nome $\nrightarrow$ Cidade

(isto é, uma pessoa pode ter mais que um telefone numa ou mais cidades)

Num dado instante podemos ter;

R

Nome	**Telefone**	**Cidade**
José da Silva	123456789	Leiria
José da Silva	222222222	Faro
António Costa	333333333	Leiria

As projecções

$R1 = \prod_{<Nome,\ Telefone>}(R)$ e $R2 = \prod_{<Nome,\ Cidade>}(R)$, no mesmo instante de tempo, teriam como resultado

R1

Nome	**Telefone**
José da Silva	123456789
José da Silva	222222222
António Costa	333333333

R2

Nome	**Cidade**
José da Silva	Leiria
José da Silva	Faro
António Costa	Leiria

A junção das duas projecções sobre o atributo Nome,

R1 $\bowtie_{<Nome = Nome>}$ R2 , é representada pela tabela

Nome	**Telefone**	**Cidade**
José da Silva	123456789	Leiria
José da Silva	123456789	Faro
José da Silva	222222222	Leiria
José da Silva	222222222	Faro
António Costa	333333333	Leiria

A junção da decomposição não é igual à relação inicial !!!

A relação não pode ser decomposta desta forma.

(10) Decomposição sem perda (Lossless Join)

Seja R(X, Y, Z) com X, Y e Z conjuntos de atributos.

Se $X \rightarrow Y$ ou $X \rightarrow Z$ então

$$R(X, Y, Z) = \prod_{<X, Y>} (R) \bowtie_{<X = X>} \prod_{<X, Z>} (R)$$

Dem:

1) Observemos em primeiro lugar que R(X,Y,Z) é sempre um subconjunto de $\prod_{<X, Y>} (R) \bowtie_{<X = X>} \prod_{<X, Z>} (R)$ (A)

Seja xyz um tuplo de R(X,Y,Z),

- se xyz está em R(XYZ) então xy está em $\prod_{<X, Y>} (R)$ e xz está em $\prod_{<X, Z>} (R)$

- a junção dos tuplos xy e xz dá o tuplo xyz

Portanto $xyz \in \prod_{<X, Y>}(R) \bowtie_{<X = X>} \prod_{<X, Z>}(R)$

2) Falta provar que se $X \rightarrow Y$ ou $X \rightarrow Z$ então

$$\prod_{<X, Y>}(R) \bowtie_{<X = X>} \prod_{<X, Z>}(R) \subseteq R(X, Y, Z)$$

(i) Supondo que $X \rightarrow Y$,

(neste caso se $xyz \in R(X, Y, Z)$ e $xy'z' \in R(X, Y, Z)$ então $y = y'$)

Se $xyz \in \prod_{<X, Y>}(R) \bowtie_{<X = X>} \prod_{<X, Z>}(R)$ então existem y' e z' tais que

$xyz' \in R(X, Y, Z)$ e $xy'z \in R(X, Y, Z)$

Mas $X \rightarrow Y$ (i) => $y = y'$ logo $xyz \in R(X, Y, Z)$

Portanto cada elemento de $\prod_{<X, Y>}(R) \bowtie_{<X = X>} \prod_{<X, Z>}(R)$ é elemento de R(X, Y, Z) B

A e B

=>

$$R(X, Y, Z) = \prod_{<X, Y>}(R) \bowtie_{<X = X>} \prod_{<X, Z>}(R)$$

q.e.d.

3.2. Normalização

A normalização de uma relação é obtida pela sua decomposição em duas ou mais relações de acordo com um procedimento bem definido.

Três níveis de normalização foram definidos por Codd:

1ª Forma Normal

2ª Forma Normal

3ª Forma Normal

Posteriormente R. Boyce e Codd definiram a

Forma Normal de Boyce-Codd (FNBC)

Mais tarde Fagin propôs:

4ª Forma Normal

5ª Forma Normal

. Uma relação numa forma normal mais avançada tem menos dados redundantes.

. Se uma relação está numa forma normal mais avançada também está nas formas normais anteriores.