

Design de Bases de Dados Relacionais

■ Tópicos:

- ★ Objetivos com o Desenho de Bases de Dados
- ★ Dependências funcionais
- ★ 1ª Forma Normal
- ★ Decomposição
- ★ Forma Normal de Boyce-Codd
- ★ 3ª Forma Normal
- ★ Visão geral sobre o processo de design

■ Bibliografia:

- ★ Capítulo 8 do livro recomendado
- ★ Capítulos 4, 5, 6 e 7 do livro *The theory of relational databases*
 - ❖ Neste último, a matéria está muito mais detalhada, e o livro está disponível online, gratuitamente, na página do autor.

Objectivos com o Design de BDs Relacionais


- Pretende-se encontrar “bons” conjuntos de esquemas relações, para armazenar os dados.
- Um “mau” design pode levar a:
 - ✦ Repetição de dados.
 - ✦ Impossibilidade de representar certos tipos de informação.
 - ✦ Dificuldade na verificação da integridade
- Objectivos do Design:
 - ✦ Evitar dados redundantes
 - ✦ Garantir que as relações relevantes sobre dados podem ser representadas
 - ✦ Facilitar a verificação de restrições de integridade.

1ª Forma Normal

- Um esquema R diz-se na 1ª forma normal se os domínios de todos os seus atributos são atômicos.
- Uma domínio é atômico se os seus elementos forem unidades indivisíveis.
 - ★ Exemplo de domínios não atômicos:
 - ❖ Conjuntos (e.g. de nomes, de telefones), atributos compostos (e.g. com nome de rua, nº de porta, código postal e localidade)
 - ❖ Identificações com partes distintas (e.g. nº de carta de condução E-111222-5, nº de BI com último dígito)
- Os valores não atômicos complicam o armazenamento e encorajam repetições desnecessárias de dados.
 - ★ Acresce que complicam desnecessariamente a definição de dependências funcionais, e não trazem nenhuma vantagem!
- Daqui para a frente, assumiremos que todas os esquemas de relações estão já na 1ª Forma Normal.

Exemplo de mau design

- Este esquema dá origem à tabela:
Amigos = (nome, telefone, cPostal, localidade)
- Este esquema não é "bom design"



nome	telef	cPostal	localidade
Maria	1111	2815	Caparica
João	2222	1000	Lisboa
Pedro	1112	1100	Lisboa
Ana	3333	2815	Caparica

Repetido!

Redundante!

- Redundância:
 - ★ Os valores de (*cPostal*, *localidade*) são repetidos para cada amigo com um mesmo código postal
 - ★ Dá azo a inconsistências
 - ★ Complica bastante a verificação da integridade dos dados
- É redundante porque *cPostal* → *localidade*

Evitar Redundância

- **1º Objetivo:** Obter um conjunto de esquemas que evite redundâncias
- Há redundância num esquema R sse existir alguma dependência funcional $\alpha \rightarrow \beta$ não trivial definida sobre R , em que α não é superchave em R
 - ✱ Dito de outra forma: Não há redundância sse para toda a dependência funcional $\alpha \rightarrow \beta$ não trivial definida sobre R , α é superchave em R
- Logo, não há redundância em R sse para toda $\alpha \rightarrow \beta \in F^+$:
 - ✱ $\beta \subseteq \alpha$ **ou**
 - ✱ Se $\alpha \subseteq R$ e $\beta \subseteq R$ então $\alpha \rightarrow \beta \in F^+$ (ou seja $R \subseteq \alpha^+$)

Forma Normal de Boyce-Codd

Um esquema R diz-se na **Forma Normal de Boyce-Codd**, **BCNF**, relativamente a um conjunto de dependências F , sse para toda a dependência em F^+ da forma $\alpha \rightarrow \beta$, onde $\alpha \subseteq R$ e $\beta \subseteq R$, pelo menos uma das condições é verdadeira:

- ★ $\alpha \rightarrow \beta$ é trivial (i.e., $\beta \subseteq \alpha$)
- ★ α é superchave de R (i.e., $\alpha \rightarrow R$)

- Evita redundâncias
- Verificação de dependências funcionais definidas sobre atributos de R , limita-se a verificação de chaves.
- Quando há redundância, ou seja quando o esquema não está na BCNF, há que decompor o esquema!

Decomposição sem perdas

- Decomposição de *Amigos* em *Amigos1* = (*nome*, *telefone*, *código_postal*) e *CPs* = (*código_postal*, *localidade*) :

nome	telef	cPostal	localidade
Maria	1111	2815	Caparica
João	2222	1000	Lisboa
Pedro	1112	1100	Lisboa
Ana	3333	2815	Caparica

Notar que é válida:
cPostal → *localidade*

nome	telef	cPostal
Maria	1111	2815
João	2222	1000
Pedro	1112	1100
Ana	3333	2815

cPostal	localidade
2815	Caparica
1000	Lisboa
1100	Lisboa

Decomposição com perdas

■ Decomposição de *Amigos* em:

★ *Amigos2* = (*nome*,*telefone*,*localidade*) e *Loc* = (*código_postal*,*localidade*).

nome	telef	cPostal	localidade
Maria	1111	2815	Caparica
João	2222	1000	Lisboa
Pedro	1112	1100	Lisboa
Ana	3333	2815	Caparica



nome	telef	localidade
Maria	1111	Caparica
João	2222	Lisboa
Pedro	1112	Lisboa
Ana	3333	Caparica

cPostal	localidade
2815	Caparica
1000	Lisboa
1100	Lisboa

Notar que **não é válida** nenhuma das dependências:

localidade → *cPostal*

localidade → *nome*, *telefone*

Decomposição sem perdas

- **2º objetivo:** Só fazer decomposições sem perdas
- Para que seja uma decomposição válida do esquema R em R_1 e R_2 , todos os atributos de R têm que aparecer ou em R_1 ou em R_2
 - ★ Formalmente: $R = R_1 \cup R_2$
- Há perda de informação sse os atributos comuns a R_1 e R_2 não são chave nem em R_1 nem em R_2
- Dito de outra forma, a decomposição é sem perdas sse os atributos comuns a R_1 e R_2 são chave em R_1 ou em R_2
- Formalmente, a decomposição de R em R_1 e R_2 é sem perdas se pelo menos uma das dependências abaixo pertence a F^+ :

$$R_1 \cap R_2 \rightarrow R_1$$

$$R_1 \cap R_2 \rightarrow R_2$$

Exemplo

- $R = (A, B, C)$
 $F = \{A \rightarrow B, B \rightarrow C\}$
- R não está em BCNF:
 - ★ $B \rightarrow C \in F$ e $\{B\}^+ = \{B, C\} \neq R = \{A, B, C\}$
- Decomposição em $R_1 = (A, B)$, $R_2 = (B, C)$
 - ★ R_1 e R_2 estão na BCNF
 - $F_1^+ = \{A \rightarrow B, \dots\}$ e $\{A\}^+ = \{A, B\} = R_1$
 - $F_2^+ = \{B \rightarrow C, \dots\}$ e $\{B\}^+ = \{B, C\} = R_2$
 - ★ Decomposição sem perdas:
 $R_1 \cap R_2 = \{B\}$ e $B \rightarrow BC \in F^+$

Teste para BCNF

- Para determinar se uma dependência não trivial $\alpha \rightarrow \beta$ é causa de violação de BCNF
 1. calcular α^+ (fecho de atributos em α), e
 2. Verificar se inclui todos os atributos de R , i.e. é superchave de R . Se incluir, está na BCNF; caso contrário não está.
- **Teste simplificado:** Em vez de verificar para todas as dependências de F^+ , verificar apenas para as dependências numa cobertura.
 - ★ Se nenhuma das dependências da cobertura violar a BCNF, então nenhuma das dependências de F^+ viola a BCNF.

Teste para BCNF

- Mas **cuidado** quando há dependências que não estão na cobertura canónica mas que estão definidas sobre o esquema!!
 - ★ E.g. Seja $R(A, B, C, D)$, com $F = \{A \rightarrow B, B \rightarrow C\}$
 - ❖ Decomposição de R em $R_1(A, B)$ e $R_2(A, C, D)$
 - ❖ Nenhuma das dependências em F contém só atributos de (A, C, D)
 - ❖ Por isso, podemos (erradamente) pensar que R_2 satisfaz BCNF.
 - ❖ Mas a dependência $A \rightarrow C \in F^+$ e portanto também pertence a F_2 , demonstrando que R_2 não está na BCNF.

Algoritmo para Decomposição BCNF

```
result := {R};  
done := false;  
calcular  $F^+$ ;  
while (not done) do  
  if (há um esquema  $R_i$  em result que não está na BCNF)  
    then begin  
      Seja  $\alpha \rightarrow \beta$  uma dependência sobre  $R_i$  tal que  
         $\alpha \rightarrow R_i \notin F^+$  e  $\alpha \cap \beta = \emptyset$ ;  
      result := (result -  $R_i$ )  $\cup$  ( $R_i - \beta$ )  $\cup$  ( $\alpha, \beta$ );  
    end  
  else done := true;
```

Nota: cada R_i está na BCNF, e a decomposição é sem perdas.

Exemplo de Decomposição BCNF

- $Amigos = (nome, telefone, código_postal, localidade)$
- $F = \{ nome \rightarrow telefone, código_postal \rightarrow localidade \}$
- Decomposição:
 - ★ $result = \{Amigos\}$
 - ❖ $código_postal \rightarrow localidade \in F^+$
 - ❖ $código_postal \rightarrow nome, telefone, código_postal, localidade \notin F^+$
 - i.e. $código_postal$ não é chave
 - ❖ $\{código_postal\} \cap \{localidade\} = \emptyset$
 - ★ $result = \{(nome, telefone, código_postal), (código_postal, localidade)\}$
 - ★ Já está na BCNF.

Outro exemplo

- $R = (\text{balcão}, \text{localidade}, \text{ativos}, \text{cliente}, \text{num_emprestimo}, \text{valor})$
 $F = \{\text{balcão} \rightarrow \text{ativos}, \text{localidade}$
 $\quad \text{num_emprestimo} \rightarrow \text{valor}, \text{balcão} \}$
Chave = $\{\text{num_emprestimo}, \text{cliente}\}$

- Decomposição

- ★ $\text{result} = \{R\}$

- ❖ $\text{balcão} \rightarrow \text{ativos}, \text{localidade} \in F^+$ e balcão não é chave em R

- ❖ $R_1 = (\text{balcão}, \text{ativos}, \text{localidade})$

- ❖ $R_2 = (\text{balcão}, \text{cliente}, \text{num_emprestimo}, \text{valor})$

- ★ $\text{result} = \{R_1, R_2\}$

- ❖ $\text{num_emprestimo} \rightarrow \text{valor}, \text{balcão} \in F_2^+$ e num_emprestimo não é chave em R_2

- ❖ $R_3 = (\text{num_emprestimo}, \text{valor}, \text{balcão})$

- ❖ $R_4 = (\text{cliente}, \text{num_emprestimo})$

- ★ $\text{result} = \{R_1, R_3, R_4\}$

- ★ Já está na BCNF

Teste de Decomposição BCNF

- Para verificar se R_i numa decomposição de R está na BCNF, pode-se testar R_i relativamente à restrição de F a R_i (i.e. todas as dependências em F^+ que só contêm atributos de R_i).
 - ✦ No entanto, obriga ao cálculo de F^+
- Pode-se usar uma cobertura de dependências sobre R mas com o seguinte teste:

- ✦ Para todo o subconjunto α de atributos de R_i , verificar se α^+ (fecho relativo a F) não inclui nenhum atributo de $R_i - \alpha$, ou inclui todos os atributos de R_i .
 - ❖ Se a condição do teste for violada para um subconjunto α de atributos de R_i , então a dependência funcional $\alpha \rightarrow (\alpha^+ - \alpha) \cap R_i$ pertence a F^+ .
 - ❖ Usa-se essa dependência para decompor R_i

gestores-bal

balcão	gestor-conta
Lisboa	Ana
Porto	Francisco
Faro	Maria

Exemplo

Redundância!

clientes

gestores		clientes	
balcão	gestor-conta	cliente	gestor-conta
Lisboa	Ana	Pedro	Ana
Porto	Francisco	Carla	Francisco
Porto	Francisco	Pedro	Francisco
Porto	Francisco	Pedro	Francisco
Faro	Maria	Pedro	Maria

- Considere o esquema
 $Gestores = (balcão, cliente, gestor-conta)$,
- com as dependências:
 1. $gestor-conta \rightarrow balcão$ (um gestor só trabalha num balcão)
 2. $cliente, balcão \rightarrow gestor-conta$ (cada cliente só tem um gestor por balcão)
- Não está na BCNF (a dependência 1 não é trivial e $gestor-conta$ não é superchave – não determina $cliente$) $\Rightarrow$ Redundância
- Usando a dependência 1 para decompor Gestores, obtemos:
 $Gestores-Bal = (balcão, gestor-conta)$ e $Clientes = (cliente, gestor-conta)$
- Agora já está na BCNF
- No entanto, não se preservam as dependências funcionais:
 - ✱ A dependência 2 não se pode verificar numa só relação, i.e. não podemos verificar que cada cliente só tem um gestor por balcão analisando separadamente as relações Gestores-Bal e Clientes.

Normalização por uso de Dependências

- Quando decompomos um esquema R com dependências F , em $R_1, R_2, \dots, R_n$ queremos
 - ★ 1º objetivo: Evitar redundância
 - ★ 2º objetivo: Decomposição sem perdas
 - ★ 3º objetivo: **Preservação de dependências**
- Seja F_i o conjunto de dependências de F^+ que só contêm atributos de R_i .
 - ❖ A decomposição **preserva as dependências** se
$$(F_1 \cup F_2 \cup \dots \cup F_n)^+ = F^+$$
 - ❖ Sem preservação de dependências, a garantia de integridade pode obrigar a considerar mais do que um esquema, sempre que se adicionam, apagam ou atualizam relações da base de dados. Tal pode tornar-se bastante ineficiente!

Exemplo

- $R = (Nome, CP, Local)$ com $F = \{Nome \rightarrow CP, CP \rightarrow Local\}$
- Decomposição de R em $R_1 = (Nome, CP)$ e $R_2 = (CP, Local)$

- ★ Decomposição sem perdas:

$$R_1 \cap R_2 = \{CP\} \text{ e } CP \rightarrow CP, Local$$

- ★ Preserva as dependências:

$$(F_1 \cup F_2)^+ = F^+ \text{ onde } F_1 = \{Nome \rightarrow CP, \dots\} \text{ e } F_2 = \{CP \rightarrow Local, \dots\}$$

- Decomposição de R em $R_1 = (Nome, CP)$ e $R_2 = (Nome, Local)$

- ★ Decomposição sem perdas:

$$R_1 \cap R_2 = \{Nome\} \text{ e } Nome \rightarrow Nome, CP$$

- ★ **Não** preserva as dependências:

$$(F_1 \cup F_2)^+ \neq F^+ \text{ onde } F_1 = \{Nome \rightarrow CP, \dots\} \text{ e } F_2 = \{Nome \rightarrow Local, \dots\}$$

- ❖ não se pode verificar $CP \rightarrow Local$ só com base em R_1 e R_2 separadamente

Teste de Preservação de Dependências

Para verificar se $\alpha \rightarrow \beta$ é preservada na decomposição R em $R_1, R_2, \dots, R_n$ aplica-se o seguinte teste:

★ *result* := α

while (alterações a *result*) **do**

for each R_i na decomposição

result := *result* $\cup ((\text{result} \cap R_i)^+ \cap R_i)$

★ Se *result* contém todos os atributos em β , então $\alpha \rightarrow \beta$ é preservada.

■ Aplica-se este teste a todas as dependências de F, para verificar se a decomposição preserva as dependências

■ Ao contrário do cálculo de F^+ e $(F_1 \cup F_2 \cup \dots \cup F_n)^+$ (que tem complexidade exponencial), este procedimento tem complexidade polinomial.

BCNF e preservação de dependências

- Nem sempre é possível obter uma decomposição BCNF que preserve as dependências.

- $R = (J, K, L)$

$$F = \{JK \rightarrow L$$

$$L \rightarrow K\}$$

Duas chaves candidatas = JK e JL

- R não está na BCNF

- Nenhuma decomposição de R preserva

$$JK \rightarrow L$$

Normalização por uso de Dependências

- Quando decompomos um esquema R com dependências F , em $R_1, R_2, \dots, R_n$ queremos
 - ✦ **Decomposição sem perdas**: Por forma a não se perder informação.
 - ✦ **Não haja redundância**: Garantido pela Forma Normal de Boyce Codd
 - ✦ **Preservação de dependências**: Para que a verificação da integridade se possa fazer relação a relação
- O algoritmo para decomposição BCNF:
 - ✦ Garante uma decomposição sem perdas.
 - ✦ Garante que as relações resultantes estão na BCNF.
 - ✦ **Não garante** a preservação das dependências!

Motivação para a 3ª Forma Normal

- Há situações em que:
 - ✦ a BCNF não preserva as dependências, e
 - ✦ a eficiência na verificação de integridade aquando de alterações é importante
- Solução: definir uma forma normal mais fraca – 3ª Forma Normal:
 - ✦ Admite alguma redundância (o que pode trazer problemas, como veremos à frente)
 - ✦ Mas as dependências podem ser verificadas relação a relação, isoladamente
 - ✦ É sempre possível fazer uma decomposição sem perdas para a 3NF, que preserva as dependências.

Exemplo Motivador

- O esquema *Gestores* = (*balcão*, *cliente*, *gestor-conta*), com as dependências:
 1. *gestor-conta* $\rightarrow$ *balcão*
 2. *cliente*, *balcão* $\rightarrow$ *gestor-conta*não estava na BCNF por causa da primeira dependência.
- As duas chaves candidatas de *Gestores* são {*cliente*, *balcão*} e {*gestor-conta*, *cliente*}. Mas:
 - ✱ Ao decompor *Gestores* com base na 1ª dependência, *balcão* vai ficar numa relação diferente daquela onde fica *cliente*.
 - ✱ Logo deixa de ser possível verificar a chave candidata {*cliente*, *balcão*} (2ª dependência funcional) de *Gestores* numa só relação!
- Solução:
 - ✱ Para se continuar a poder verificar a chave candidata da relação original, a solução é não permitir a decomposição de um esquema com base numa dependência que à direita contenha apenas alguns dos atributos de uma chave candidata.

3ª Forma Normal

Um esquema R está na 3ª Forma Normal (3FN) sse para toda:

$$\alpha \rightarrow \beta \in F^+$$

pelo menos uma das condições é verdadeira:

- ✱ $\alpha \rightarrow \beta$ é trivial (i.e., $\beta \subseteq \alpha$)
- ✱ α é superchave de R (i.e., $\alpha \rightarrow R \in F^+$)
- ✱ Todo atributo $A \in (\beta - \alpha)$ está contido numa chave candidata de R .
(NOTA: cada um dos atributos pode pertencer a uma chave candidata distinta)

- A 3ª condição relaxa a BCNF para garantir que é possível uma decomposição com preservação de dependências
- Se R está na BCNF então está também na 3FN

Exemplo

- Esquema *Gestores* = (*balcão*, *cliente*, *gestor-conta*) com as dependências:

- gestor-conta* → *balcão*
- cliente*, *balcão* → *gestor-conta*

gestores

<i>balcão</i>	<i>cliente</i>	<i>gestor-conta</i>
Lisboa	Pedro	Ana
Porto	Carla	Francisco
Porto	Pedro	Francisco
Faro	Pedro	Maria

Redundância!

- Tem duas chaves candidatas: {*cliente*, *balcão*} e {*gestor-conta*, *cliente*}.
- Está na 3ªFN porque:
 - balcão* ∈ {*cliente*, *balcão*} que é chave candidata
 - {*cliente*, *balcão*} é supechave
- Não está na BCNF porque dep. func. 1. não é trivial e *gestor-conta* não é superchave.
- Decomposição BCNF:

Não preserva a dependência funcional
cliente, *balcão* → *gestor-conta*

clientes

<i>cliente</i>	<i>gestor-conta</i>
Pedro	Ana
Carla	Francisco
Pedro	Francisco
Pedro	Maria

gestores-bal

<i>balcão</i>	<i>gestor-conta</i>
Lisboa	Ana
Porto	Francisco
Faro	Maria

Teste para 3FN

- Otimização: Basta verificar para uma cobertura de F (não é necessário verificar para toda a dependência em F^+)
- Usar fecho de atributos para verificar, em toda a dependência $\alpha \rightarrow \beta$, se α é superchave.
- Se α não for superchave, há que verificar se todo o atributo em $\beta - \alpha$ pertence a alguma chave candidata de R
 - ✦ Este teste é bastante ineficiente, pois envolve o cálculo de chaves candidatas
 - ✦ Pode demonstrar-se que verificar se um conjunto de esquemas está na 3FN tem complexidade NP-hard (muito complexo!)
 - ✦ No entanto, é possível fazer a decomposição para a 3FN em tempo polinomial

Algoritmo de Decomposição para 3FN

Seja F_c uma cobertura canônica de F ;

$i := 0$;

for each $\alpha \rightarrow \beta \in F_c$ **do**

if nenhum dos esquemas R_j , $1 \leq j \leq i$ contém $\alpha \beta$

then begin

$i := i + 1$;

$R_i := \alpha \beta$

end

if nenhum dos esquemas R_j , $1 \leq j \leq i$ contém uma chave candidata de R

then begin

$i := i + 1$;

$R_i :=$ uma (qualquer) chave candidata de R ;

end

return $(R_1, R_2, \dots, R_i)$

Exemplo

- Considere o esquema:

Info-Gestores = (balcão, cliente, gestor-conta, gabinete)

- As dependências definidas sobre este esquema são:

gestor-conta → balcão, gabinete

cliente, balcão → gestor-conta

- As chaves candidatas são:

{cliente, balcão} e *{gestor-conta, cliente}*

- Info-Gestores não está na 3FN. Considerando a dependência funcional *gestor-conta → balcão, gabinete*, verificamos que:

✱ *gestor-conta* não é superchave;

✱ *gabinete* $\notin$ chave candidata.

- O ciclo **for** do algoritmo leva à introdução dos seguintes esquemas na decomposição:

Gestores-gab = (gestor-conta, balcão, gabinete)

Gestores = (cliente, balcão, gestor-conta)

- Como *Gestores* contém uma chave candidata de *Info-Gestores*, {cliente, balcão}, o processo de decomposição termina.

Exemplo

- Esquema *Gestores* = (*balcão*, *cliente*, *gestor-conta*, *gabinete*) com as dependências:

1. *gestor-conta* → *balcão*, *gabinete*

2. *cliente*, *balcão* → *gestor-conta*

info-gestores

balcão	cliente	gestor-conta	gabinete
Lisboa	Pedro	Ana	1.1
Porto	Carla	Francisco	2.1
Porto	Pedro	Francisco	2.1
Faro	Pedro	Maria	3.1

Redundância!

- Não está na BCNF nem na 3NF

- Decomposição BCNF:

Não preserva a dependência funcional
cliente, *balcão* → *gestor-conta*

gestores-bal

balcão	gestor-conta	gabinete
Lisboa	Ana	1.1
Porto	Francisco	2.1
Faro	Maria	3.1

clientes

cliente	gestor-conta
Pedro	Ana
Carla	Francisco
Pedro	Francisco
Pedro	Maria

- Decomposição 3NF:

gestores-gab

balcão	cliente	gestor-conta
Lisboa	Pedro	Ana
Porto	Carla	Francisco
Porto	Pedro	Francisco
Faro	Pedro	Maria

Redundância!

gestores

balcão	gestor-conta	gabinete
Lisboa	Ana	1.1
Porto	Francisco	2.1
Faro	Maria	3.1

Outro exemplo

- Considere o esquema:

$$R = (A, B, C)$$

- Com as dependências:

$$A \rightarrow C$$

$$B \rightarrow C$$

- A chave candidata é:

$$\{ A, B \}$$

- O ciclo **for** do algoritmo, leva à introdução dos seguintes esquemas na decomposição:

$$R_1 = (A, C)$$

$$R_2 = (B, C)$$

- Como nem R_1 nem R_2 contém a chave candidata de R o processo de decomposição adiciona ainda:

$$R_3 = (A, B)$$

Mais um exemplo

- Considere o esquema $\text{Semestre}=(C,P,H,S,A,N)$ representando a informação relativa à componente prática de uma dada cadeira num semestre, onde $C=\text{Cadeira}$, $P=\text{Professor}$, $H=\text{Hora}$, $S=\text{Sala}$, $A=\text{Aluno}$ e $N=\text{Nota}$.

- Considere as seguintes dependências funcionais:

$$F = \{C \rightarrow P, HS \rightarrow C, HP \rightarrow S, CA \rightarrow N, HA \rightarrow S, HSP \rightarrow CS\}$$

- Primeiro determina-se uma cobertura canónica:

$$F_c = \{C \rightarrow P, HS \rightarrow C, HP \rightarrow S, CA \rightarrow N, HA \rightarrow S\}$$

- Chaves candidatas: $\{A,H\}$

- Ciclo **for**: cria as seguintes 5 relações, correspondentes às 5 dependências funcionais da cobertura canónica:

$$R_1=(C,P) \quad R_2=(H,S,C) \quad R_3=(H,P,S) \quad R_4=(C,A,N) \quad R_5=(H,A,S)$$

- Como já existe uma relação (R_5) contendo uma chave candidata ($\{A,H\}$), não é necessário criar mais relações.

Propriedade do algoritmo de Decomposição

- O algoritmo descrito garante que:
 - ✱ Todo o esquema R_i está na 3FN
 - ✱ A decomposição preserva as dependências e é sem perdas
- Note que só é garantido que se preservam as dependências no conjunto de todas as relações da decomposição. Mesmo que exista um subconjunto dessas relações que contenha todos os atributos da relação original, não se garante que, nele, as dependências sejam preservadas.
- A decomposição de $R = (A,B,C)$, com $A \rightarrow C$ e $B \rightarrow C$, em:
$$R_1 = (A, C) \quad R_2 = (B,C) \quad R_3 = (A, B)$$
preserva as dependências:
 - ✱ $F_1 = \{A \rightarrow C, \dots\}$, $F_2 = \{B \rightarrow C, \dots\}$, $F_3 = \{\dots\}$ e $(F_1 \cup F_2 \cup F_3)^+ = F^+$
- Mas $(F_1 \cup F_3)^+ \neq F^+$, apesar de $R_1 \cup R_3 = R$!!
- Em particular $B \rightarrow C \in F^+$ mas $B \rightarrow C \notin (F_1 \cup F_3)^+$

Propriedade do algoritmo de Decomposição

- O resultado do algoritmo não é único pois depende:
 - ✱ da cobertura canónica utilizada
 - ✱ da chave candidata de R utilizada
 - ✱ nalguns casos, também da ordem pela qual se consideram as dependências funcionais

BCNF versus 3NF

- É sempre possível decompor um esquema, num conjunto de esquemas na 3FN em que:
 - ✦ a decomposição é sem perdas
 - ✦ as dependências são preservadas
 - ✦ Mas pode haver alguma redundância!!
- É sempre possível decompor um esquema, num conjunto de esquemas na BCNF em que
 - ✦ a decomposição é sem perdas
 - ✦ não há redundância
 - ✦ Mas nem sempre se podem preservar as dependências!!

BCNF ou 3NF?

- Objetivos do design, numa primeira fase:
 - ✦ BCNF.
 - ✦ Decomposição sem perdas.
 - ✦ Preservação de dependências.
- Porquê?
 - ✦ Porque assim, todas as dependências funcionais se podem testar impondo superchaves em relações, isoladamente
 - ✦ Nos SGBD esses testes são muito eficientes!
- Se tal não for possível, então há que optar por uma de
 - ✦ Admitir algumas inconsistência – **Esta é a pior das soluções!**
 - ✦ BCNF e fazer testes entre tabelas para dependências não preservadas
 - ✦ 3NF e fazer testes adicionais para evitar inconsistência vinda de redundância
 - ✦ Veremos mais à frente, como é que se podem fazer esses testes
- Como escolher entre BCNF e 3NF?
 - ✦ Depende de que testes forem mais eficientes
 - ❖ mas isso depende em muito do tipo de uso da BD
 - ✦ Eficiência não é o foco desta UC

E se estiver na BCNF e não preservar dependência?

- Manter, para além das tabelas decompostas, a tabela antes da decomposição que deu origem à não preservação de dependências
 - ✦ Nessa tabela redundante, impor como chave a dependência que é preservada na BCNF
 - ✦ Isto exige manter essa tabela atualizada sempre que há alterações (novos tuplos, mas também remoções e edições)
 - ✦ E duplica o espaço ocupado!
- Isto é mau no caso de tabelas que sofrem alterações frequentes
 - ✦ Especialmente mau se, além disso, a tabela redundante for muito grande!

E se estiver na 3FN e não na BCNF?

- Há que verificar dependências funcionais que não são chave!
- Para verificar $\alpha \rightarrow \beta$ quando α não é chave
 - ✱ Sempre que se quer inserir um novo tuplo, cria-se uma cópia da tabela e ordena-se essa cópia por α
 - ✱ Percorre-se a tabela ordenada e verifica-se em cada grupo de α s iguais se há mais que um β
 - ✱ Complexidade é pior que linear
 - ❖ Se tabela tem 1 milhão de tuplos, mais do que um milhão de operações!!
- Isto é muito mau no caso de tabelas potencialmente grandes!
 - ✱ Mas só é mau se a introdução de novos tuplos for frequente
 - ❖ Só é preciso verificar quando se introduzem novos tuplos na tabela

BCNF ou 3FN?

■ *Rule of thumb*

- ✦ Se se espera que a tabela na 3NF (que não está na BCNF) seja muito grande, tenha muitas introduções de dados mas poucas remoções e edições, então **optar pela BCNF**
- ✦ Se não se espera que a tabela seja (mesmo) muito grande ou se espera que tenha muitas remoções e edições então **optar pela 3FN**

■ Claro que esta regra, só assim, é muito falível

■ Como é que podem fazer melhor?

- ✦ Fazendo a cadeira de Sistemas de Bases de Dados :-)
- ✦ Para melhorar eficiência de bases de dados (mesmo) muito grandes, esta cadeira não chega!
 - ❖ Esta é a primeira cadeira de bases de dados; não é a última
 - ❖ A eficiência nem está nos seus objetivos
 - ❖ Mas é aqui que aprendem todos os conceitos para a criação e manipulação de uma base de dados, e chega para fazer até bases de dados bem grandes – mas talvez não chegue para garantir a eficiência em bases de dados com vários milhões de tuplos

Mais Formas Normais

- **Dependências multivalor** – parecida com dependências funcionais
 - ✱ $\alpha \twoheadrightarrow \beta$ - α não garante valor único de β , mas se houver vários são sempre os mesmo, em todo o lado
 - ✱ Dão origem à **4ª forma normal**
- As **dependências de junção** generalizam as multivalor
 - ✱ Dão origem à **forma normal projecção-junção (PJNF)** (também chamada de **5ª forma normal**)
- Uma classe ainda mais geral de restrições leva à **forma normal de domínio-chave**.
- Problemas com estas restrições muito gerais:
 - ✱ é difícil raciocinar sobre elas
 - ✱ não têm conjuntos coerentes e completos de regras de inferência.
- Logo, raramente são usadas

Visão global sobre o design

- Temos assumido que o esquema R é dado
 - ✦ R pode ter sido obtido ao passar um diagrama E-R para tabelas.
 - ✦ R pode ser uma única relação contendo *todos* os atributos de interesse para os dados (**relação universal**).
 - ❖ A normalização irá decompor R em relações mais pequenas.
 - ✦ R pode ser o resultado de algum design ad hoc.

Modelo ER e Normalização

- Quando o diagrama E-R está ***mesmo*** bem feito, as tabelas geradas em princípio nem necessitam de mais normalização.
- No entanto, na prática há diagramas ER imperfeitos que levam a que dependências que queremos impor não tenham o lado esquerdo como chave.
- E.g. Entidade *empregado* com atributos *cod_departamento* e *morada_dep*, e a dependência *cod_departamento* → *morada_dep*
 - ★ Num bom design *departamentos* seria um outro conjunto de entidades

Desnormalização para Performance

- Para melhorar a performance, podemos querer usar esquema não normalizados
- E.g. mostrar *customer-name* juntamente com *account-number* e *balance* exige juntar informação de *account* com *depositor*
- Alternativa: Usar relação desnormalizada que contém atributos de *account* e de *depositor*
 - ✦ execução mais rápida de perguntas
 - ✦ gasta mais espaço, e mais tempo para atualizações
 - ✦ é mais passível de erros
- Para ser menos passível de erros, veremos mais à frente como evitar esses erros programando verificação de restrições na base de dados
 - ✦ Mas continua a gastar mais espaço e, dependendo da programação, nem sempre vai ser muito mais eficiente
 - ❖ E, novamente, aqui ainda nem sabemos bem como é a eficiência...

Outros aspectos do design

- Alguns aspectos do design de bases de dados não são captados pela normalização
- Exemplos de mau design, a evitar:

Em vez de *lucros(compANHIA, ano, valor)*, usar

★ *lucros-2000, lucros-2001, lucros-2002*, etc., todas com esquema (*compANHIA, valor*).

❖ Todas estas relações estão na BCNF. Mas dificulta a execução de perguntas sobre vários anos, e exige nova tabela todos os anos

★ *compANHIA_ano(compANHIA, lucros-2000, lucros-2001, lucros-2002)*

❖ Também está na BCNF, mas também dificulta perguntas sobre vários anos, e exige novo atributo todos os anos.

❖ É um exemplo de **crosstab**, onde valores para um atributo se transformam em nomes de atributos

❖ Usado em folhas de cálculo e em ferramentas de análise de dados

Um “cheirinho” de SBD - Chaves

■ Para impor (super)chaves

- ✦ Guardam-se os vários valores dos atributos da chave numa estrutura de dados complicada (B⁺-trees)
- ✦ Sempre que se quer inserir um novo tuplo, verifica-se se o valor da chave já lá está – se estiver não introduz

■ Este teste tem complexidade $\log_K N$, onde N é o número de valores diferentes e K é de algumas dezenas (e depende do n° de bytes ocupado pelo atributo chave)

- ✦ Mesmo muito eficiente!
- ✦ E.g. se $K = 50$ (o que é uma valor muito normal) e a tabela tiver 1 milhão de tuplos
 - ❖ $\log_{50}(1.000.000) < 4$ operações
 - ❖ Operação na ordem de mili-segundos!

Exemplo de Decomposição BCNF (sem calcular F^+)

- Problema: decompor para a BCNF a relação $R(A,B,C,D,E,F,G,H)$ com $F = \{A \rightarrow BCH, CH \rightarrow CD, E \rightarrow FG, G \rightarrow CH, A \rightarrow CD\}$

- Decomposição:

$R_1(A,E,F,G)$

$R_2(A,B,C,D,H)$

$R_3(A,E)$

$R_4(E,F,G)$

$R_5(A,B,C,H)$

$R_6(C,D,H)$

```
result := {R};
done := false;
calcular  $F^+$ ;
while (not done) do
  if (há um esquema  $R_i$  em result que não está na BCNF)
  then begin
    Seja  $\alpha \rightarrow \beta$  uma dependência sobre  $R_i$  tal que
       $\alpha \rightarrow R_i \notin F^+, e \alpha \cap \beta = \emptyset$ ;
    result := (result -  $R_i$ )  $\cup$  ( $R_i - \beta$ )  $\cup$  ( $\alpha, \beta$ );
  end
else done := true;
```

Para todo o subconjunto α de atributos de R_i , verificar se α^+ (fecho relativo a F) não inclui nenhum atributo de $R_i - \alpha$, ou

$R_4(E,F,G)$ está na BCNF?

Testar para cada $\alpha \subset R_4$ se

Após testar de forma semelhante as relações $R_5(A,B,C,H)$ e $R_6(C,D,H)$, conclui-se que também estão na BCNF.

$\alpha = \{G\} \Rightarrow \alpha^+ = \{C,D,G,H\}$. Não viola 1 $\Rightarrow$ ok.

$\alpha = \{EF\} \Rightarrow \alpha^+ = \{C,D,E,F,G,H\}$. Não viola 2 $\Rightarrow$ ok.

$\alpha = \{EG\} \Rightarrow \alpha^+ = \{C,D,E,F,G,H\}$. Não viola 2 $\Rightarrow$ ok.

$\alpha = \{FG\} \Rightarrow \alpha^+ = \{C,D,F,G,H\}$. Não viola 1 $\Rightarrow$ ok.

Logo, está na BCNF!

Exemplo de Verificação de Preservação de DFs (sem calcular F^+)

- **Problema:** a decomposição de $R(A,B,C,D,E,F,G,H)$ com $F = \{A \rightarrow BCH, CH \rightarrow CD, E \rightarrow FG, G \rightarrow CH, A \rightarrow CD\}$

Em $R_3(A,E)$, $R_4(E,F,G)$,
 $R_5(A,B,C,H)$, $R_6(C,D,H)$

preserva as dependências funcionais?

Para verificar se $\alpha \rightarrow \beta$ é preservada na decomposição R em $R_1, R_2, \dots, R_n$ aplica-se o seguinte teste:

result := α

while (alterações a result) **do**

for each R_i na decomposição

 result := result $\cup ((\text{result} \cap R_i)^+ \cap R_i)$

Se result contém todos os atributos em β , então $\alpha \rightarrow \beta$ é preservada.

$A \rightarrow BCH$ é preservada?

Result = $\{A\}$

$A \rightarrow CD$ é preservada?

Result = $\{A\}$

1ª iteração:

Result = $\{A\} \cup ((\{A\} \cap R_3)^+ \cap R_3) \cup ((\{A\} \cap R_4)^+ \cap R_4) \cup ((\{A\} \cap R_5)^+ \cap R_5) \cup ((\{A\} \cap R_6)^+ \cap R_6) =$
 $= \{A\} \cup \{A\} \cup \emptyset \cup \{A,B,C,H\} \cup \emptyset =$
 $\{A,B,C,H\}$

2ª iteração:

Result = $\{A,B,C,H\} \cup ((\{A,B,C,H\} \cap R_3)^+ \cap R_3) \cup ((\{A,B,C,H\} \cap R_4)^+ \cap R_4) \cup ((\{A,B,C,H\} \cap R_5)^+ \cap R_5) \cup ((\{A,B,C,H\} \cap R_6)^+ \cap R_6) =$
 $= \{A,B,C,H\} \cup \{A\} \cup \emptyset \cup \{A,B,C,H\} \cup \{C,H,D\} =$
 $= \{A,B,C,D,H\}$

Cmo Result já contém $\{C,D\}$, a dependência funcional $A \rightarrow CD$ é preservada.

Notar que ela é preservada apesar de não haver nenhuma relação que contenha todos os atributos da dependência funcional.

Com o mesmo teste, verifica-se que a dependência funcional $A \rightarrow BCH$ é preservada.

Esta conclusão poderia ser tirada após a 1ª iteração ou por observação directa que R_5 contém todos os atributos da dependência funcional.