

Il modello dimensionale

Luca Cabibbo
aprile 2012

Il modello dimensionale

L'organizzazione dei dati del data warehouse costituisce la pietra angolare dell'intero sistema DW/BI

- le applicazioni BI, di supporto alle decisioni, accedono i dati direttamente dal DW
 - l'organizzazione dei dati nel DW deve sostenere sia la comprensibilità dei dati di business che buone prestazioni
- il sottosistema ETL è dedicato a trasformare i dati estratti dalle sorgenti informative in una forma adeguata al caricamento nel DW
- la modellazione dimensionale si è dimostrata la tecnica più valida per l'organizzazione dei dati nel DW

Modellazione dimensionale, in breve

Organizzazione dei dati in un DW

- i dati di interesse per ciascun processo di business dell'organizzazione sono rappresentati mediante un *modello dimensionale* – anche chiamato *data mart*
 - in un data mart, i dati di interesse sono *misure* (di solito numeriche) del processo (*fatti*) – ciascun fatto è caratterizzato da un *contesto* (prevalentemente testuale) vero nel momento in cui il fatto è stato catturato (*dimensioni*)

Modellazione dimensionale, in breve

Organizzazione dei dati in un DW

- inoltre, è necessario che i dati nei diversi data mart/modelli dimensionali siano organizzati in modo conforme (coerente) – per questo viene adottata un'*architettura a bus del data warehouse*
 - nell'ambito dei diversi processi di business, i dati sono organizzati attorno a un insieme di *dimensioni conformi* e di *fatti conformi*
 - questa conformità serve ad assicurare che i dati nei diversi data mart, relativi a processi diversi, possano essere correlati e integrati nell'ambito dell'intero data warehouse e nel corso del tempo

Processi di business

Un **processo di business** (o **processo aziendale**, **business process**) è un evento o attività operativa principale per l'organizzazione

- ad esempio, il processo di gestione degli ordini
- di solito supportato da un sistema sorgente – da cui è possibile collezionare le misure di prestazioni associate
- pertanto, è possibile pensare a ciascun processo di business come a una sorgente di dati principale per il DW

I processi di business sono importanti nella modellazione dimensionale

- i processi di business possono essere usati come criterio per il raggruppamento coerente delle risorse informative dell'organizzazione e dei dati del data warehouse
- un data warehouse viene realizzato mediante uno o più data mart per ciascun processo di business di interesse

Modelli dimensionali/data mart

Un **modello dimensionale per un processo di business** – anche chiamato semplicemente **modello dimensionale** o **data mart** – rappresenta nel DW i dati di interesse relativi ad uno specifico processo di business

- detto in altri modi
 - un data mart è un sottoinsieme logico dell'intero data warehouse
 - un data mart è la restrizione del data warehouse a un singolo processo di business
 - il data warehouse è l'unione dei data mart che lo costituiscono

Data warehouse dimensionali

Un **data warehouse dimensionale** è un data warehouse realizzato come unione di un insieme di modelli dimensionali (data mart) che hanno le seguenti caratteristiche

- ogni data mart, relativo a un processo di business, è un insieme di schemi dimensionali
 - ogni *schema dimensionale* è organizzato in termini di misure (*fatti*) e contesto (*dimensioni*)
- viene adottata un'**architettura a bus del data warehouse** – **data warehouse bus architecture** – ovvero, i vari data mart sono costruiti usando
 - dimensioni conformi (o conformate)
 - ciascuna dimensione ha lo stesso significato in ciascuno schema dimensionale e data mart
 - fatti conformi
 - anche i fatti hanno un'interpretazione uniforme

Dati multidimensionali

L'organizzazione logica dei dati in un modello dimensionale è descritta in termini di fatti e dimensioni

- secondo la prospettiva degli utenti di business del sistema DW/BI – e non secondo i modelli (ad es., quello relazionale) adottati nei sistemi che gestiscono le sorgenti informative
- un **fatto** rappresenta una misurazione delle prestazioni di un processo di business
 - una misura, di solito numerica e additiva, del processo da analizzare
- una **dimensione** rappresenta una prospettiva rispetto alla quale effettuare l'analisi
 - una dimensione rappresenta un'informazione del contesto in cui è stata catturata una misurazione delle prestazioni del processo di business di interesse
 - le dimensioni descrivono domini discreti, solitamente organizzati in livelli di aggregazione

Dati multidimensionali – esempi

Modello dimensionale per il processo delle vendite

- fatto: vendite dei prodotti, giornaliera, per negozio
- dimensioni: prodotto, tempo (giorno), negozio, promozione
- misure: quantità venduta, incasso, costo, conteggio dei clienti

Modello dimensionale per il processo telefonate


- fatto: telefonata
- dimensioni: chiamante, chiamato, tariffa, tempo (giorno), tempo (ora del giorno)
- misure: durata, costo

Schema dimensionali

Uno **schema dimensionale** – chiamato anche **star schema** o **schema a stella** – è una base di dati relazionale, usata per rappresentare dati multidimensionali – uno schema dimensionale è di solito composto da

- una tabella principale, chiamata **tabella fatti**
 - la tabella fatti memorizza i fatti misurabili di un processo
 - i fatti più comuni sono numerici, continui e additivi
- alcune tabelle ausiliarie, chiamate **tabelle dimensione**
 - ciascuna tabella dimensione fornisce un contesto ai fatti della tabella fatti – inoltre, rappresenta una dimensione rispetto alla quale è interessante analizzare i fatti
 - memorizza i membri della dimensione, che caratterizzano la granularità dei fatti, nonché gli attributi (solitamente testuali, discreti e descrittivi)

Esempio di schema dimensionale



- questo schema modella i dati delle vendite di prodotti in un certo numero di negozi nel corso del tempo
 - memorizza i totali giornalieri delle vendite dei prodotti per negozio

11

Il modello dimensionale

Luca Cabibbo

Scopo di uno schema dimensionale

In uno schema dimensionale

- una *tabella dimensione* serve a rappresentare un insieme di elementi (un insieme in senso matematico), chiamati *membri della dimensione*
- una *tabella fatti* serve a memorizzare un insieme di funzioni numeriche (funzioni in senso matematico)

Nell'esempio, lo schema rappresenta

- una dimensione **Product** di tipi di prodotti in vendita
- una dimensione **Time** di giorni in un intervallo di interesse
- una dimensione **Store** dei negozi di una catena di negozi
- una funzione **dollars_sold**: **Product** × **Time** × **Store** → **R**
- una funzione **units_sold**: **Product** × **Time** × **Store** → **N**

12

Il modello dimensionale

Luca Cabibbo

Tabelle dimensione

Una **tabella dimensione** (**dimension table**) memorizza una dimensione rispetto a cui è di interesse analizzare un processo

- una **dimensione** è un dominio (insieme) di elementi, chiamati membri
 - ad es., un insieme di prodotti o un insieme di negozi
- ciascun **membro** della dimensione è rappresentato da una riga della tabella dimensione
 - ad es., ciascuna riga della tabella **Product Dimension** descrive uno dei prodotti in vendita nella catena di negozi
- la chiave è semplice e artificiale – di solito è un intero
- gli altri campi (non chiave) della tabella dimensione memorizzano gli **attributi** dei membri
 - gli attributi sono le proprietà dei membri – che sono solitamente testuali, discrete e descrittive
 - sono usati dalle interrogazioni per vincolare e raggruppare i fatti

13

Il modello dimensionale

Luca Cabibbo

Tabelle dimensione

Time Dimension

time_key	date	...
1	1/1/2009	...
2	2/1/2009	...
3	3/1/2009	...
...
...
...
...
...
...
1461	31/12/2011	...

Product Dimension

product_key	description	...
1	Lattina Coca Cola	...
2	Lattina Coca Cola Diet	...
3	Tubo Pringles Original	...
...
...
...
...
...
...
9827	Spaghetti De Cecco	...

store_key	store_name	...
1	MegaStore Marconi (RM)	...
2	MegaStore EUR (RM)	...
...
...
...
...
49	HyperStore Duomo (MI)	...

Store Dimension

14

Il modello dimensionale

Luca Cabibbo

Tabella fatti

Una **tabella fatti** (**fact table**) memorizza le misure numeriche (fatti) di un processo di business

- per **fatto** si intende una specifica misura delle prestazioni di un processo di business
- ogni fatto viene misurato durante un momento significativo dell'erogazione di un processo – con un contesto ben preciso, descritto da un insieme di membri, uno per ciascuna delle dimensioni significative per il fatto
 - per definire questo contesto, la chiave della tabella fatti è composta da chiavi esterne verso le varie tabelle dimensione, che referenziano i membri coinvolti
- gli altri campi rappresentano i fatti
 - questi fatti sono solitamente numerici, continui e additivi
- ciascuna riga della tabella fatti memorizza un insieme di misure (fatti) associati ad una particolare combinazione di membri, presa all'intersezione di tutte le dimensioni

15

Il modello dimensionale

Luca Cabibbo

Tabella fatti

Time Dimension

time_key	date	...
1	1/1/2009	...
2	2/1/2009	...
3	3/1/2009	...
...
...
...
...
...
1461	31/12/2011	...

Sales Fact

time	prd	store	dollars sold	units sold
...
3	2	1	9.48	12
3	3	49	9.45	7
...
...
...

Product Dimension

product_key	description	...
1	Lattina Coca Cola	...
2	Lattina Coca Cola Diet	...
3	Tubo Pringles Original	...
...
...
...
...
...
9827	Spaghetti De Cecco	...

store_key	store_name	...
1	MegaStore Marconi (RM)	...
2	MegaStore EUR (RM)	...
...
...
...
...
49	HyperStore Duomo (MI)	...

Store Dimension

16

Il modello dimensionale

Luca Cabibbo

Tabella fatti

Una tabella fatti serve

- a memorizzare un insieme di funzioni numeriche (in senso matematico)
 - una funzione per ciascuno dei fatti
 - il cui dominio è dato dall'insieme delle dimensioni
 - ciascuna di queste funzioni (parziale) associa un valore a ciascuna possibile combinazione dei membri delle dimensioni
- in un modo adeguato per l'analisi dimensionale

Nell'esempio

- una funzione **dollars_sold**: **Product** × **Time** × **Store** → **R**
- una funzione **units_sold**: **Product** × **Time** × **Store** → **N**

Schemi dimensioni, processi e grana

Ciascuno schema dimensionale serve a rappresentare i fatti di interesse per un certo processo di business, ad una certa granularità

- nell'esempio, il processo è la vendita di prodotti nei negozi di una catena di negozi
- i fatti sono
 - l'incasso in dollari (**dollars_sold**)
 - la quantità venduta (**units_sold**)
- in questo caso, la granularità a cui sono rappresentati di dati sono *il totale giornaliero per prodotto e negozio*

Additività dei fatti

Un fatto è **additivo** se ha senso sommarlo rispetto a ogni possibile combinazione delle dimensioni da cui dipende

- nell'esempio, l'incasso in dollari è additivo – infatti ha senso calcolare la somma degli incassi per un certo intervallo di tempo, insieme di prodotti e insieme di negozi
 - ad esempio, in un mese, per una categoria di prodotti e per i negozi in un'area geografica

L'additività è una proprietà importante, perché le applicazioni di BI devono spesso combinare (aggregare) i fatti descritti da molte righe di una tabella fatti

- il modo più comune di combinare un insieme di fatti è di sommarli (se questo ha senso)
- è possibile anche l'uso di altre operazioni – ad esempio, min, max, avg

Semi additività e non additività

I fatti possono essere anche

- **semi additivi**
 - se ha senso sommarli solo rispetto ad alcune dimensioni
 - ad esempio, il numero di pezzi in deposito di un prodotto è sommabile rispetto alle categorie di prodotto e ai magazzini, ma non rispetto al tempo
- **non additivi**
 - se non ha senso sommarli
- può avere senso combinare fatti anche non completamente additivi mediante operazioni diverse dalla somma
 - ad esempio, min, max

Sulla scelta delle chiavi

Alcuni commenti circa l'uso delle chiavi nei vari tipi di tabelle in uno schema dimensionale

- la chiave primaria di ciascuna tabella dimensione deve essere semplice e artificiale (“surrogata”)
 - tipicamente, un semplice numero intero
 - non deve avere nessun significato “naturale”
 - le chiavi originali “di produzione” non vanno assolutamente usate
 - perché? riuso di chiavi naturali, cambiamento delle chiavi naturali, dimensioni che cambiano lentamente, ...
 - corrispondenza con tra chiavi naturali e chiavi artificiali gestita nell'area di preparazione dei dati
- le chiavi delle tabelle fatti sono composte da chiavi esterne delle tabelle dimensione coinvolte

Attributi e interrogazioni

Gli attributi delle tabelle dimensione sono il principale strumento per l'interrogazione del data warehouse

- gli attributi delle dimensioni vengono usati principalmente con due finalità
 - per selezionare un sottoinsieme dei dati di interesse
 - vincolando il valore di uno o più attributi
 - ad esempio, le vendite nel corso dell'anno 2011
 - per raggruppare i dati di interesse
 - usando gli attributi come intestazioni della tabella risultato
 - ad esempio, per mostrare le vendite per ciascuna categoria di prodotto in ciascun mese

Attributi e interrogazioni

Un esempio di interrogazione

- somma degli incassi in dollari e delle quantità vendute
- per ciascuna categoria di prodotto in ciascun mese
- nel corso dell'anno 2011

(product) category	(time) month	(sum of) dollars_sold	(sum of) units_sold
Drinks	gennaio 2011	21.509,05	23.293
Drinks	febbraio 2011	19.486,93	22.216
Drinks	marzo 2011	21.986,43	23.532
Food	gennaio 2011	86.937,77	55.135
Supplies	gennaio 2011	21.554,17	13.541

23

Il modello dimensionale

Luca Cabibbo

Formato delle interrogazioni

Le interrogazione assumono solitamente la seguente forma standard



- sono comuni anche interrogazioni che effettuano confronti e/o rapporti (tassi)

24

Il modello dimensionale

Luca Cabibbo

Drill down

L'operazione di drill down aggiunge dettaglio ai dati restituiti da una interrogazione

- il drill down avviene aggiungendo un nuovo attributo nell'intestazione di un'interrogazione
- diminuisce la grana dell'aggregazione – aumenta il dettaglio dei dati

(product) category	(time) month	(sum of) dollars_sold	(sum of) units_sold
-----------------------	-----------------	--------------------------	------------------------



drill down

(product) category	(time) month	(store) city	(sum of) dollars_sold	(sum of) units_sold
-----------------------	-----------------	-----------------	--------------------------	------------------------

Drill up

L'operazione di drill up riduce il dettaglio dei dati restituiti da una interrogazione

- il drill up avviene rimuovendo un attributo dall'intestazione di un'interrogazione
- aumenta la grana dell'aggregazione – diminuisce il dettaglio dei dati

(product) category	(time) month	(sum of) dollars_sold	(sum of) units_sold
-----------------------	-----------------	--------------------------	------------------------



drill up

(product) category	(sum of) dollars_sold	(sum of) units_sold
-----------------------	--------------------------	------------------------

Discussione

Per il data warehouse, la modellazione dimensionale presenta dei vantaggi rispetto alla modellazione tradizionale (ER-BCNF) adottata nei sistemi operazionali

- gli schemi dimensionali hanno una forma standardizzata e prevedibile
 - è facilmente comprensibile e rende possibile la navigazione dei dati
 - semplifica la scrittura delle applicazioni
 - consente una strategia di esecuzione efficiente
- gli schemi dimensionali hanno una struttura simmetrica rispetto alle dimensioni
 - la progettazione può essere effettuata in modo indipendente per ciascuna dimensione
 - le interfacce utente e le strategie di esecuzione sono simmetriche


Vantaggi della modellazione dimensionale

Ulteriori vantaggi, che vedremo successivamente

- gli schemi dimensionali sono facilmente estendibili
 - rispetto all'introduzione di nuovi fatti
 - rispetto all'introduzione di nuovi attributi per le dimensioni
 - rispetto all'introduzione di nuove dimensioni "supplementari"
 - se ogni record della tabella fatti dipende già funzionalmente dai membri della nuova dimensione
- si presta alla gestione e materializzazione di dati aggregati
- sono state già sviluppate numerose tecniche per la descrizione di tipologie fondamentali di fatti e dimensioni
 - ad esempio, dimensioni lentamente variabili, prodotti eterogenei, tabelle fatti senza fatti,
 - alcune di queste tecniche saranno presentate nel seguito di questo corso

Snowflaking

Per snowflaking di una dimensione si intende una rappresentazione “più normalizzata” di una tabella dimensione, che evidenzia delle “gerarchie di attributi”



Occupazione di memoria

Stima dell'occupazione di memoria della base di dati dimensionale di esempio

- tempo
 - 2 anni di 365 giorni, ovvero 730 giorni
- negozi
 - 300 negozi
- prodotti
 - 30.000 prodotti
- fatti relativi alle vendite
 - ipotizziamo un livello di sparsità del 10% delle vendite giornaliere dei prodotti nei negozi
 - ovvero, che ogni negozio vende giornalmente 3.000 diversi prodotti
 - $730 \times 300 \times 3000 = 630.000.000$ record

Resistere allo snowflaking

Lo snowflaking è solitamente svantaggioso

- inutile per l'occupazione di memoria
 - ad es., una dimensione prodotto con 30.000 record, di circa 2.000 byte ciascuno -> 60MB di memoria primaria
 - tabella fatti con invece 630.000.000 record, di circa 10 byte ciascuno -> 6.3GB di memoria primaria
 - le tabelle fatti sono sempre molto più grandi delle tabelle dimensione associate
 - anche riducendo l'occupazione di memoria della dimensione prodotto del 100%, l'occupazione di memoria complessiva è ridotta di meno dell'1%
- può peggiorare le prestazioni
- tuttavia, ci sono delle situazioni in cui è utile definire delle "sottodimensioni" – con l'apparenza di uno snowflake
 - si veda la tecnica delle mini-dimensioni