

3. Vežbe

Projektovanje i Implementacija ETL procesa. Materijalizovani pogledi

Izvođači laboratorijskih vežbi

- Marko Knežević (kancelarija TMD 9b)
- Nikola Obrenović

Termin konsultacija

- Marko Knežević: petak 15:00 TMD 9b
marko.knezevic(AT)uns.ac.rs
- Nikola Obrenović
nikob(AT)uns.ac.rs

ETL osnove

- Extract – Transform – Load
- Predstavlja proces koji migrira podatke iz izvornih sistema/baza/fajlova u DW bazu podataka
- Mora da uskladi iste podatke iz različitih sistema po tipu, ograničenjima i semantici
- MS SQL Server Integration Services (SSIS)
- MS Business Intelligence Development Studio


Razvoj ETL procesa

- Odrediti tehnologije koje će se koristiti za ekstrakciju
- Definisati dokaz da je migracija uspešna
- Definisati mesto gde se ispravljaju greške – poželjno je da to bude u izvornom sistemu
- Arhivirati izvorne podatke - Da li potrebno?
- Definisati ETL plan

ETL plan

- ETL plan - specifikacija transformacija za svaki određeni DW atribut:
 - koji su ulazni podaci
 - funkcija koja transformiše ulazne podatke u DW atribut
- Sprovesti profilisanje podataka
- Sprovesti analizu nedostajućih vrednosti i odrediti kako da se one nadoknade
- Saradivati sa vlasnicima podataka
- Definisati mehanizme za inkrementalni ETL proces u okviru izvora podataka

ETL Plan



ELT proces

- ETL proces predstavlja skup paketa koji se izvršavaju po definisanom redosledu i/ili u paraleli
- ETL paket \approx C# Procedura
- Postoji glavni ETL paket koji upravlja izvršavanjem svih ostalih
- Preporuka: jedan paket puni jednu tabelu u DW ili staging bazi
- Odvojeni ETL procesi, jedan za prvi load i jedan za naredne inkrementalne

Glavni ETL paket

MDWT_2008 - Microsoft Visual Studio (Administrator)

File Edit View Project Build Debug Data Format SSIS Tools Test Window Help

Solution Explorer - Solution 'MDWT_2008...'

- Solution 'MDWT_2008' (1 project)
 - MDWT_2008
 - Data Sources
 - MDWT 2008.ds
 - MDWT 2008 Stage.ds
 - MDWT 2008 dotNet.ds
 - Data Source Views
 - SSIS Packages
 - RUN THIS TO LOAD ALL.dtsx
 - Date.dtsx
 - OrderInfo.dtsx
 - Promotion.dtsx
 - Currency.dtsx
 - Employee.dtsx
 - Product_SQL.dtsx
 - Customer.dtsx
 - ExchangeRates.dtsx
 - Orders_SQL.dtsx
 - Product_SIS.dtsx
 - Orders_Lookups.dtsx
 - Miscellaneous
 - TruncateTables.sql

Promotion.dtsx [Design]* Customer.dtsx [Design] MDWT 2008.ds [XML] RUN THIS TO LOAD ALL.dtsx [Design]

Control Flow Data Flow Event Handlers Package Explorer

BEFORE YOU RUN THIS PACKAGE FOR THE FIRST TIME, Please be sure to have created the directory: c:\ssistemp

This package is the master package that runs the dimension packages. Look at the Connection Managers window below this package. You can see a connection to each package. We are assuming you've copied down the solution and sorted the package to: c:\mdwt_projects\mdwt_2008\mdwt_adventureworks. If you put the solution somewhere else, simply go into the Connection Managers window, and point it to the correct location.

Get AuditKey

Currency

Date


Employee

Product

ETL primeri

- Primere kopirati na lokaciju C:\MDWT_Projects
- Napraviti folder C:\SSIStemp

ELT Paket – Control Flow



Control flow

- postoji samo jedan control flow po paketu
- sekvenca taskova
- najkorišćeniji tipovi taskova:
 - Execute SQL
 - Execute package
 - Data flow
 - Script
- Data flow task sadrži logiku transformacije podataka

Data Flow

The screenshot displays the SSIS Data Flow Task design for 'Load DimPromotion'. The task is composed of the following components:

- Source Adapter:** Source from Special O...
- Transforms:** Fix NULL, Row Metadata, Row Count
- Destination Adapter with error handling:** Bulk load DimPromo...
- Row by row**
- Count Errors**
- Error rows to raw file**

The flow is indicated by green arrows, with a red arrow showing a break in the flow between the Bulk load and Row by row components.

Poslovna
podatak:

a podataka

Data Flow

- Jedan ili više izvora podataka - izvor podataka je prethodni control flow task
- Niz transformacija
- Jedan ili više odredišta podataka – naredni control flow taskovi

Error Flow


- Alternativni data flow
- Izvor ili transformacija definiše koji slogovi završavaju u error flow
- Primeri:
 - Neuspela konverzija podataka
 - Podaci nezadovoljavaju specificirano ograničenje
- Greška u jednom redu:
 - može da se zaustavi ceo proces
 - da se preskoči red
 - da se ispravi greška

Control i Data Flow taskovi

- MSDN: <http://msdn.microsoft.com/en-us/library/ms139892.aspx>


Extract Data

- definisati izvor podataka
- SSIS podržava OLE DB i .Net providere (MS ili od nekog drugog proizvođača)
- ako izvor podataka nema provider, najlakše je prvo eksportovati podatke u csv/txt fajlove
- podaci se ekstrakuju neizmenjeni u staging bazu ili fajlove
- minimizira se opterećenje izvornog sistema



Loading Data


- 2 načina:
 - red po red: sporo
 - bulk: svi redovi odjednom, brzo




Cleaning Data

- sastavni deo data flow taska
- 2 načina čišćenja podataka na nivou kolone:
 - kroz SQL upit za load podataka (Product_SQL.dtsx)
 - upotrebom data flow taskova (Product_SSIS.dtsx):


- Lookup transformacija



- Derived Column transformacija



- Union transformacija



- omogućava da se otkriju problemi u izvorima podataka

Conforming Data


- Usklađivanje podataka između različitih sistema:
 - Detekcija duplikata: Fuzzy Lookup i Fuzzy Grouping transformacije
 - Konsolidacija podataka po tipu, ograničenjima i formatu

Load dimenzija


- Implementirati surogatni ključ IDENTITY kolonom
- Hijerarhije se prave spajanjem tabela iz izvora ili se prave u Excelu (npr. vremenska dimenzija)
- Junk dimenzije se prave spajanjem tabela ili iz Excela/skripte
- Inkrementalni load bez SPD:
 - Za male dimenzije – truncate i ponovno punjenje
 - update (OLE DB transformacija)
 - insert u posebnu tabelu pa izvršiti MERGE naredbu

Sporo promenjive dimenzije

- Dodati kolone RowStartDate, RowEndDate (i RowsCurrent)
- Upotreba wizzarda Slowly Changing Dimension



Sporo promenjive dimenzije



Load činjenice

- Odvojeni ETL paketi, jedan za prvi (bulk) load i jedan za naredne inkrementalne
- (Bulk) insert ili update naredbe nad tabelom činjenica
- Tri tipa činjenice:
 - transakcija
 - presek (snapshot)
 - akumulirana

Load činjenice

- Transaction grain činjenica
 - Bulk load: insert
 - Inkrementalni load: update (OLE DB transformacija) ili insert u posebnu tabelu pa izvršiti MERGE naredbu
- Snapshot činjenica
 - red se ažurira svakodnevno i zamrzne se na kraju perioda – zahteva dve ETL transformacije
 - Inkrementalni load: update (OLE DB transformacija) ili insert u posebnu tabelu pa izvršiti MERGE naredbu
- Akumulirane činjenice
 - Ažuriranje jednog istorijskog podatka može da izazove izmenu na velikom broju redova - uglavnom je brže ponovo load-ovati (delete+insert) poslednjih n meseci

Load činjenice

- Strani surogatni ključevi se dodeljuju Lookup operacijom tokom data flow-a
- Ako lookup ne uspe (odluka zavisi od zahteva):
 - preskočiti red činjenice
 - prebaciti nevalidne redove u posebnu tabelu
 - napraviti placeholder za dimenziju
 - prekinuti obradu
- Primer: Orders_Lookups.dtsx
- Iako su Lookup operacije navedene serijski, SSIS ih automatski paralelizuje

Load činjenice

- Alternativni pristup dodele stranih surogatnih ključeva: SQL upiti sa spojevima tabela
- Koristi se OUTER JOIN da bi se pokupile sve činjenice
- Primer: Orders_SQL.dtsx

Audit dimenzija

- sadrži red za svaki put kada je SSIS paket
- sadrži informacije ko je i kada je pokrenuo paket
- svaka tabela u DW sadrži dva strana ključa ka Audit tabeli:
 - jedan definiše kada je red kreiran i
 - drugi definiše kada je poslednji put ažuriran

Kašnjenje

- Zakasnele dimenzije:
 - napraviti novi red ukoliko je dimenzija tipa 2 i prevezati činjenice
 - StartDate novog reda je timestamp od koga važi nova vrednost dimenzije
 - EndDate novog reda je EndDate stagor reda
- Zakasnele činjenice
 - identifikovati dimenziju u odgovarajuće vremenskom trenutku preko StartDate i EndDate kolona

Error Schema

- Skup tabela koji je namenjen da se loguju greške tokom ETL procesa
- „Error” tabele
 - po strukturi iste sa ciljnim tabelama dimenzione šeme
 - Smeštaju se redovi koji imaju grešku
 - Tabele mogu biti smeštene i u obične fajlove

Materijalizovani pogledi

- SQL Server termin - indexed view
- Kreirati unique clustered index nad pogledom:


```
CREATE UNIQUE CLUSTERED INDEX <ind_name>  
ON <table_name> (<col_name>);
```
- Samo kolona <col_name> postaje sastavni deo indeksa ali sve kolone pogleda se čuvaju u bazi
- Pogled se automatski ažurira kad se ažuriraju tabele
- Optimizator upita samostalno pronade i koristi materijalizovane poglede

Kada se kreiraju materijalizovani pogledi?

- Tipovi aplikacija:
 - Data marts
 - Data warehouses
 - OLAP stores and sources
 - Data mining workloads.
- Aplikacije koje imaju sledeće funkcionalnosti:
 - Spojevi i agregacije velikih tabela
 - Često ponavljani kompleksni upiti
 - Ponavljajuće agregacije nad istim skupom kolona
 - Ponavljani spojevi istih tabela nad istim ključevima

Ubrzanje performansi

- MSDN: The represented queries varied in complexity (for example, the number of aggregate calculations, the number of tables used, or the number of predicates) and included large multi-million row tables from a real production environment.



Kada se NE kreiraju materijalizovani pogledi?

- Nad tabelama OLTP sistema gde su česta ažuriranja
- Automatsko održavanje materijalizovanog pogleda postaje preskupo

Materijalizovai pogledi

- Preduslovi:
 - Pogled sme da referencira samo tabele a ne i druge poglede
 - Sve referencirane tabele moraju biti u istoj bazi kao i pogled i imati istog vlasnika
 - Pogled mora biti kreiran sa SCHEMABINDING opcijom, koja povezuje pogled sa šemom kojoj pripadaju tabele
 - Korisničke funkcije koje referencira pogled takođe moraju biti kreirane sa SCHEMABINDING opcijom
 - Tabele i funkcije u definiciji pogleda moraju biti navedene sa nazivom šeme