



Pentaho Data Integration
5 miliona zapisa u 10 minuta, svaki dan

Goran Cvijanović
Vinteh d.o.o.

Sadržaj prezentacije

- **Zablude oko implementacije skladišta podataka**
- **Arhitektura integracije podataka i ETL procesa**
- **Open source alati za integraciju podataka**
- **Pentaho Open source BI**
- **Primjena Pentaho Data Integration platforme**
- **Zaključak**

Zablude oko implementacije SP-a

- Sustav koji prikuplja, pročišćava, verificira i isporučuje izvorišne podatke u dimenzionalna skladišta podataka, te osigurava i implementira upitne i analitičke module za podršku poslovnom odlučivanju
- Korisnika smještamo u centar razvoja skladišta podataka, značaj pojedinih komponenti ima drugačiji pogled
- Put do točnih i upotrebljivih podataka, ETL procesi
- Podsjetnik prilikom planiranja izgradnje skladišta podataka

- Možemo li kupiti gotovo rješenje koje će biti naše skladište podataka?
 - Ne. Moramo ga izgraditi ili prilagoditi, jer naše poslovanje nije identično nekom drugom
 - Sam proces izgradnje uključuje analizu poslovnih procesa i izvođača podataka, manipulaciju podacima, modeliranje dimenzijskih struktura i korisničkih sučelja
- Za izgradnju skladišta podataka ne koristi se jedinstven programski jezik
 - Njega čini više komponenti koje uključuju različite programske arhitekture
- Projekt skladišta podataka čine grupe manjih projekata i faza
 - Implementacija se izvodi u više nezavisnih projekata koji omogućavaju da se izgradnja osnovnog skupa funkcionalnosti provede do kraja
 - Time se omogućava da projekt skladišta podataka bude uspješan, upravljiv i izvediv u zadanom vremenu
- Model podataka ne predstavlja skladište podataka
 - Čak i najbolje osmišljen model je beskoristan bez kvalitetnih podataka i razumljive prezentacije
- Kopiranje proizvodnog sustava na novi poslužitelj zbog ubrzanja izvještavanja ne čini taj sustav skladištem podataka
 - Bez promjene strukture onemogućena je osnovna namjena skladišta podataka, podrške poslovnom odlučivanju

Arhitektura IP i ETL procesa

- Pogled od 360 stupnjeva na poslovne podatke, predstavlja moderni termin za pojam integracije podataka
- Postići zadovoljavajuću kvalitetu integriranih podataka, kroz osiguravanje kvalitetnog izvora transakcijskih podataka
- Usklada dimenzija s ciljem postizanja jednakih vrijednosti
- Usklada vrijednosti za mjere značajna je za mogućnost izgradnje takozvanih ključnih indikatora
- Izbor arhitekture je elementaran i potrebno ga je odraditi u ranoj fazi planiranja ETL sustava
- Dva osnovna puta, korištenje gotovog rješenja tehnološkog partnera ili izgradnja vlastitog ETL sustava

Prednosti i nedostaci pojedinog modela

GOTOVO RJEŠENJE

- Jednostavniji, brži i jeftiniji razvoj
- Efikasno korištenje alata i bez poznavanja o programskih jezika i programiranja
- Postojanje među-podatkovnog sloja (metadata) za postizanje uniformnosti
- Postojanje predefiniranih konektora za mnoštvo izvorišnih i odredišnih sustava
- Korištenje ugrađenih funkcija za sigurne komunikacije, enkripcije i kompresije
- Dobre performanse i podrška za rad s velikim količinama podataka
- Podrška za rad u klasteriranim i sustavima, osiguranje integriteta

Prednosti i nedostaci pojedinog modela

VLASTITI RAZVOJ

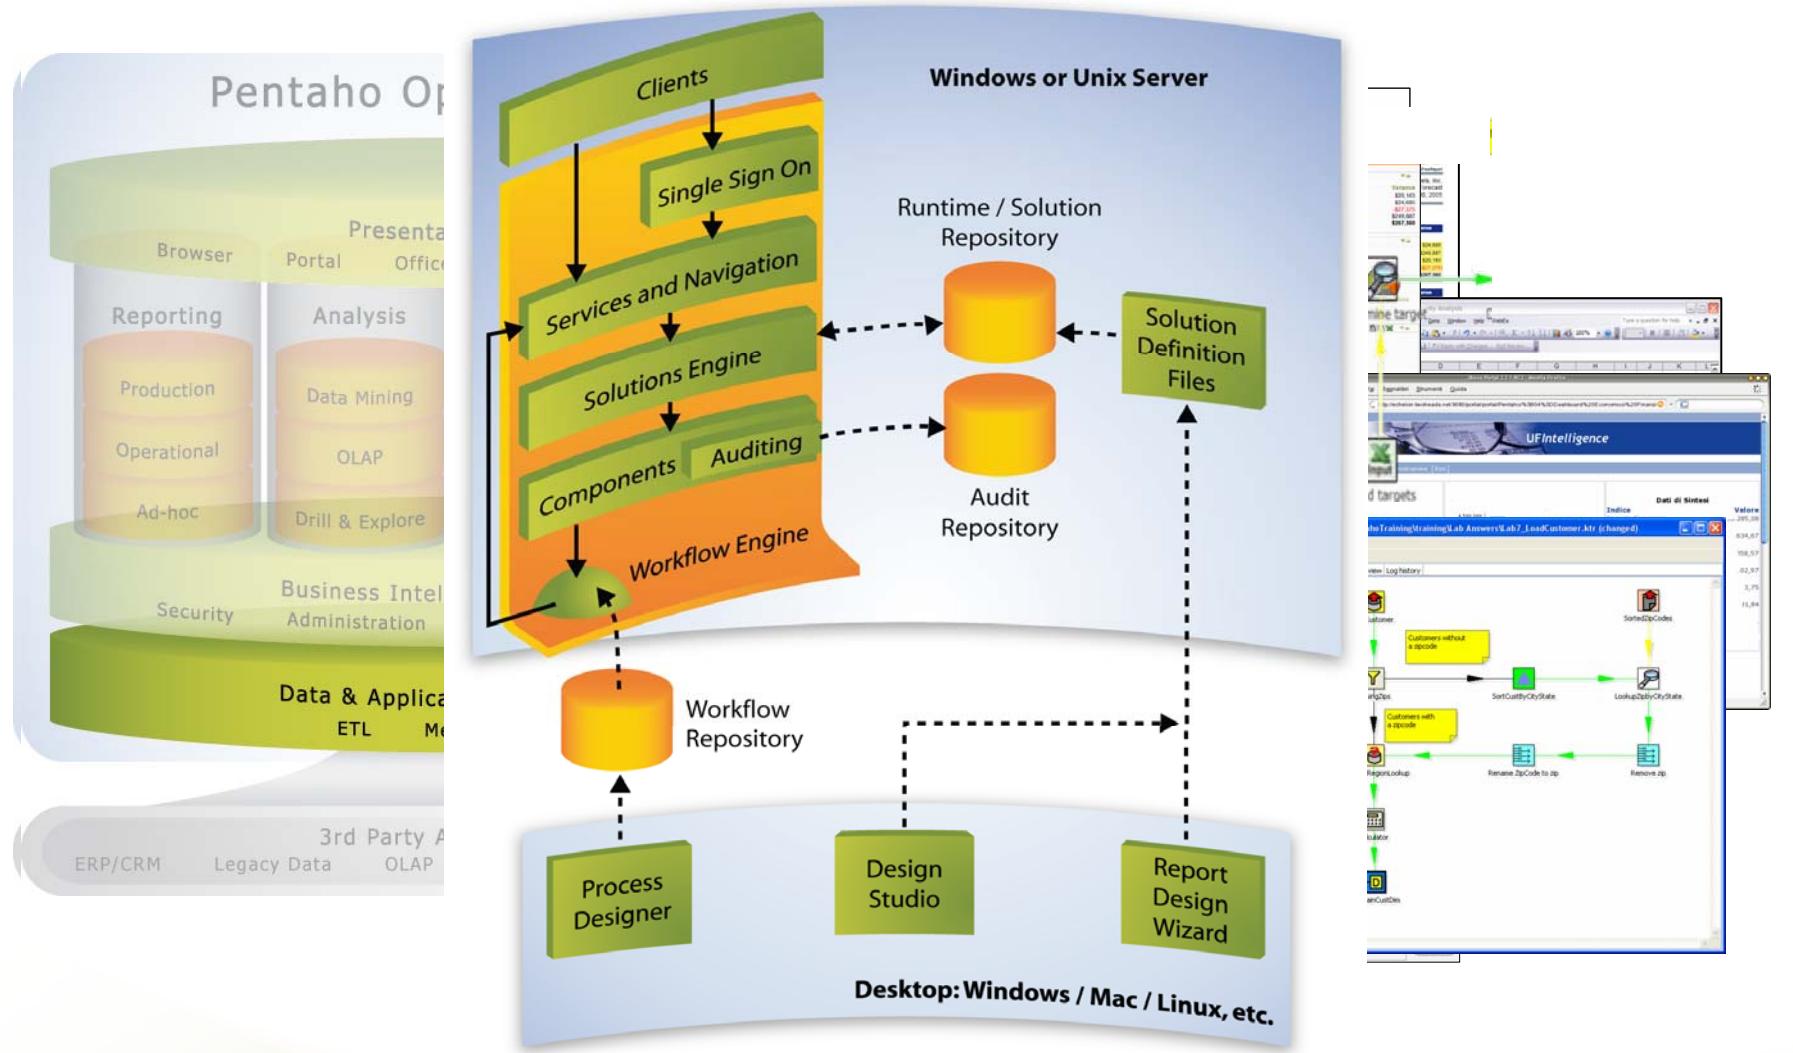
- Mogućnost integralnog procesa testiranja korištenjem alata za testiranje
- Objektno orientirane tehnike omogućuju koegzistentnost i nadzor nad graškama
- Nezavisnost od proizvođača alata za ETL, kao i puna fleksibilnost u korištenju poznatih razvojnih alata i jezika

-
- Idealno bi bilo imati rješenje koje nudi osobine iz obije grupe, gotovo rješenje sa svim svojim prednostima i mogućnostima, ali i dostupnost izvornog koda uz poznavanje programske platforme na kojoj je izrađeno
 - Kao takva mogućnost su open source rješenja koja predstavljaju već zrele produkte i rješenja koja mogu zadovoljiti široku paletu namjene

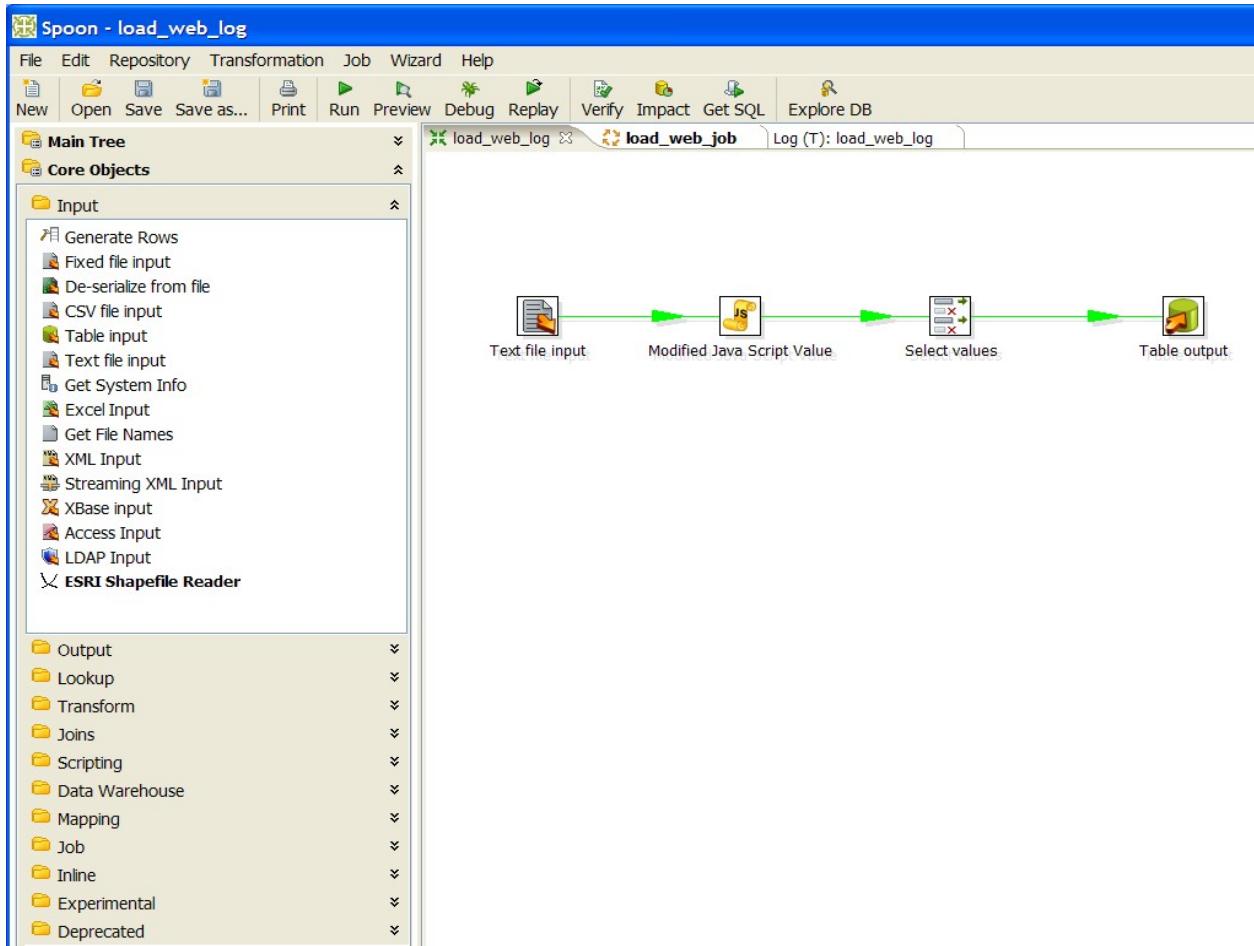
Open source alati i platforme za BI

- **Pentaho** - najpoznatije open source rješenje, uključuje izvještajni sustav, analize, prezentacijsku platformu (dashboard) i rudarenje podataka (data mining).
- **JasperSoft** - poznato ime iz svijeta izvještajnih open source platformi, nastalo udruživanjem Jasper Reports i iReport platformi
- **Actuate Corporation** - **BIRT** platforma koja je dio Eclipse fondacije. Predstavlja platformu koja se intezivno razvija uz veliku podršku matične kompanije
- **Spago BI** - tvrtka koja nudi kompletno open source rješenje, u kombinaciji s profesionalnim implementatorima koji mogu izvesti složene projekte

Pentaho Open source BI



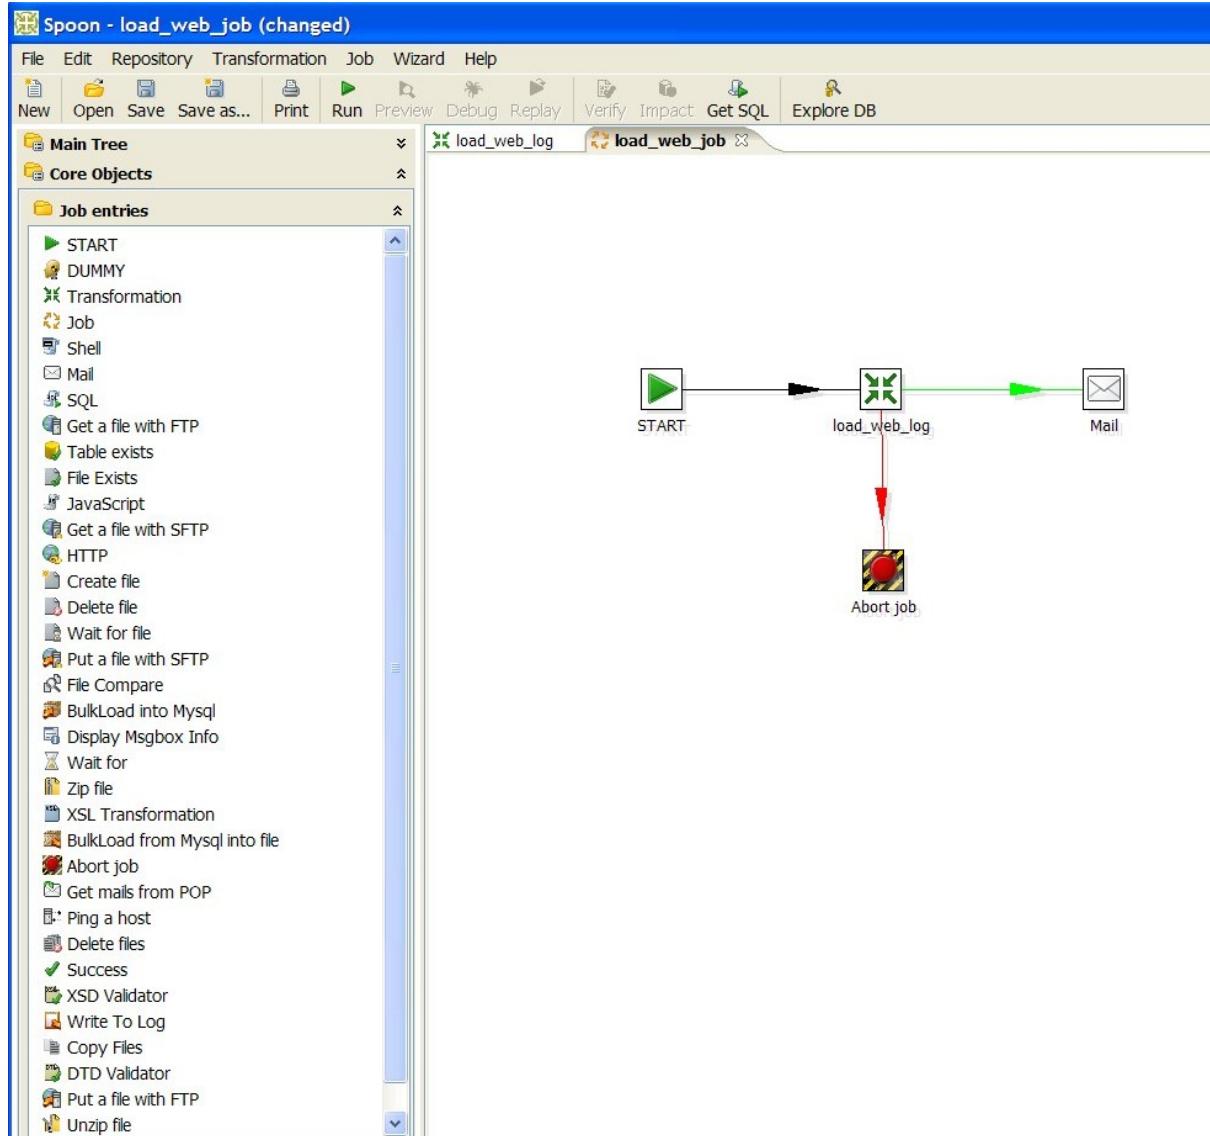
Primjena Pentaho Data Integration platforme



Upotreba

- Kao sistemska platforma koriste se Linux serveri
- Java Runtime Environment verzije 1.4 ili noviji
- Podržane platforme su: Microsoft Windows uključujući i Vista verziju, Linux, Apple OSx, Solaris, AIX, HP-UX, FreeBSD
- Spoon, Pan i Kitchen moduli aplikacijske platforme

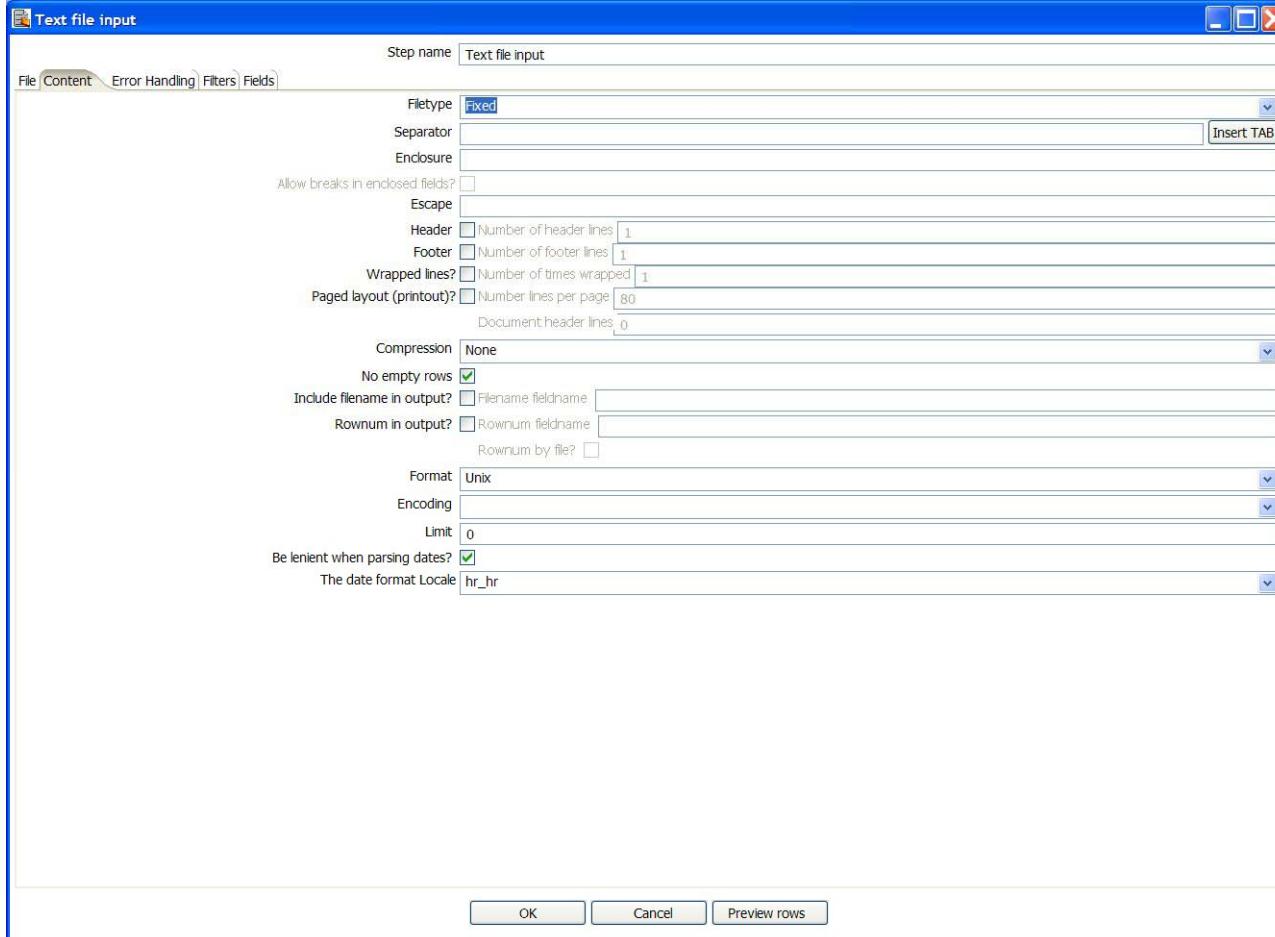
Prikaz PDI Spoon modula



Spoon modul

- Osnovni modul koji se koristi za modeliranje i izvršavanje transformacija i upravljačkih procesa
- Proces koji opisujemo je učitavanje web logova koji su standardne Apache Web Server strukture
- Izvršni proces sadrži elemente i njihove tokove, u ovom slučaju oznaku početka procesa, pokretanje transformacije, te grananje u slučaju greške prekid procesa, a u slučaju uspješnog izvršenja slanje mail poruke o obavljenom poslu

Izvedbeni koraci - učitavanje iz tekstualne datoteke



Opis

- Odabran je rad s redovima u datoteci koji su fiksne veličine, nisu dozvoljeni prazni redci, te se radi o Unix formatu završetka retka
- Učitava se cijeli jedan redak u jedno tekstualno polje, a u sljedećem koraku će se odraditi izdvajanje pojedinih elemenata iz teksta

Izvedbeni koraci - Java script

Script Values / Mod

Step name: Modified Java Script Value

Java script functions :

- Transform Scripts
- Transform Constants
- Transform Functions
- Input Fields
- Output Fields

Java script :

```

//Script here
var cookiePos = line.getString().indexOf("wpcid=");
var ipPos = line.getString().indexOf("\\" );
var ipEnd = line.getString().indexOf('[' );
var wsesPos = line.getString().indexOf(']' );
var wsesEnd = line.getString().indexOf(' \\' );
var iduaPos = line.getString().indexOf('?id=' );
var idtmPos = line.getString().indexOf('&tm=' );
var idtmEnd = line.getString().indexOf(" HTTP");

var cookie = "-";

if(cookiePos != -1) { cookie = line.getString().substr(cookiePos+6,24); }

var ip = line.getString().substr(ipPos+2,ipEnd-ipPos-2);
var wdate = line.getString().substr(ipEnd+2,11);
var wtime = line.getString().substr(ipEnd+14,8);
var whour = line.getString().substr(ipEnd+14,2);
var offset = line.getString().substr(ipEnd+23,5);
var wsession = line.getString().substr(wsesPos+2,wsesEnd-wsesPos-2);

var idua = "";
if (iduaPos != -1) { idua = line.getString().substr(iduaPos+4,idtmPos-iduaPos-4); }
if (idua == "undefined" | idua == "null" | idua == "") { idua = "UNDEF"; }

var idtm = "";
if (idtmPos != -1) { idtm = line.getString().substr(idtmPos+4,idtmEnd-idtmPos-4); }

```

Linenr: 0
Compatibility mode?

Fields

#	Fieldname	Rename to	Type	Length	Precision
1	cookie		String	24	
2	ip		String	15	
3	wdate		String	11	
4	offset		String	6	
5	wsession		String	10	
6	idua		String	15	
7	idtm		String	20	
8	wtime		String	8	
9	whour		String	2	

OK Cancel Get variables Test script

Opis

- Izdvajanje pojedinih elemenata iz teksta napravljeno je pomoću Java script jezika
- Elementarnom poznавање sintakse i načina kako rastaviti tekstualno polje na pojedine elemente pomoću predefiniranih razdjelnika u sadržaju teksta
- Sva su polja usklađena sa strukturom kolona u tablici Oracle baze podataka

Izvedbeni koraci - mapiranje i pohranjivanje u bazu

Select / Rename values

Step name: Select values

Select & Alter | Remove | Meta-data

Fields :

#	Fieldname	Rename to	Length	Precision
1	cookie			
2	ip			
3	wdate			
4	wtime			
5	idua			

Get fields to select | Edit Mapping

Table output

Step name: Table output

Connection: XE

Target schema: WLG

Target table: WEB_LOG

Commit size: 100

Truncate table:

Ignore insert errors:

Use batch update for inserts:

Partition data over tables:
Partitioning field:

Partition data per month:
Partition data per day:

Is the name of the table defined in a field?
Field that contains name of table:
Store the tablename field:

Return auto-generated key:
Name of auto-generated key field:

OK | Cancel | SQL

Opis

- Mapiranje u oblik pogodan za spremane u bazu podataka
- S obzirom da smo vodili računa o veličini pojedinih varijabli i njihovom tipu, mapiranje se trivijalno svodi na popis varijabli koje imaju jednak naziv kao i kolone u tablici web_log Oracle baze
- Povezivanje s velikim brojem relacijskih baza podataka omogućeno je već nakon instalacije

Zaključak

Za napomenuti

- Bitni segmenti u fazama razvoja produkta su svježina ideja i smjernice razvoja, veliki broj korisnika koji aktivno testiraju i prijavljuju uočene probleme, podrška u rješavanju problema
 - Pentaho Data Integration je alat koji omogućava da se poslovi koji čine ETL proces obave brzo i pomoću alata u kojem je ugrađeno znanje o tome kako nešto napraviti, a na stručnjaku je da odredi što treba napraviti
 - kompletna podrška za zapisivanje informacija o odvijanju procesa, statističkih podataka interaktivno kroz alat, kao i mogućnosti pohranjivanja tih podataka u datoteke ili baze podataka koji se nadalje mogu analizirati ili proslijedivati putem mail sustava

Pitanja za kraj

Pentaho Commercial Open Source Business Intelligence - Mozilla Firefox

Southeast Region

Customer #99
Name: Tarallo Inc
Location: Sanford, FL
Current Sales: \$1,000,000

Spending

Headcount Spending by Region



Region	Spending	Percentage
Eastern	\$35,248,040	25%
Southern	\$36,248,040	25%
Central	\$37,803,162	26%
Western	\$35,248,040	25%

Revenue for the year 2005



Month	Products	Services	Total
Jan	\$0.5M	\$2.2M	\$2.7M
Feb	\$0.5M	\$2.2M	\$2.7M
Mar	\$0.5M	\$2.2M	\$2.7M
Apr	\$0.5M	\$2.2M	\$2.7M
May	\$0.5M	\$2.2M	\$2.7M
Jun	\$0.5M	\$2.2M	\$2.7M
Jul	\$0.5M	\$2.2M	\$2.7M
Aug	\$0.5M	\$2.2M	\$2.7M
Sep	\$0.5M	\$2.2M	\$2.7M
Oct	\$0.5M	\$2.2M	\$2.7M
Nov	\$0.5M	\$2.2M	\$2.7M
Dec	\$0.5M	\$2.2M	\$2.7M

Current Year What-If Analysis

Region: **EAST**

	Sales	Costs of Goods	Profit	Operating Income
Sales:	\$167,816,979	\$149,188,879	\$18,628,100	\$68,628,100
Costs of Goods:	\$167,816,979	\$149,188,879	\$18,628,100	\$68,628,100
Profit:	\$167,816,979	\$149,188,879	\$18,628,100	\$68,628,100
Operating Income:	\$167,816,979	\$149,188,879	\$18,628,100	\$68,628,100

Sales : 0% **Costs :** 0%