


```

4780 GOTO 5000
4790 :
4800 REM
4801 REM
4802 REM
4803 REM
4810 :
4820 PRINT
4825 W=V+1
4830 FOR X
4835 FOR I
4840 PRINT
4850 NEXT:
4860 PRINT
4870 FOR I
4880 IF MD
(I+1);:GOT
4890 PRINT
4900 NEXT
4910 PRINT
4920 FOR I
4925 PRINT
4930 IF MD
";:GOTO 4
4935 PRINT
4940 NEXT:PRINT"
4950 PRINT"XXXXXXXXXXXXXXXXX";
4960 FOR I=2 TO 24 STEP 2
4965 PRINT"|";
4970 IF MD$(I+W-1)="X X" THEN PRINT"X"
MB$(I)"X";:GOTO 4980
4975 PRINT MB$(I);
4980 NEXT:PRINT"X"

```

Datová kvalita

RNDr. Ondřej Zýka



This is a WHERE clause



And this is the SUM



Datová kvalita

Jedna z kompetencí Data managementu

Cíl: Zajistit uživatelům data v „kvalitě“ potřebné k jejich činnosti

Kvalita dat:

Subjektivní pojem závislý na požadavcích a zkušenosti uživatelů, na způsobu použití dat

Kvalita dat není dána jejich strukturou nebo uložením.

Dimenze datové kvality

Dimenze	Popis
Dostupnost	Zda jsou informace k dispozici nebo snadno získatelné
Odpovídající velikost a granularita dat	Zda velikost dat a jejich granularita odpovídá vykonávaným úlohám
Věrohodnost	Zda jsou informace pokládány za pravdivé a důvěryhodné
Úplnost	Zda žádná data nechybí a zda jsou dostatečné rozsáhlá a detailní pro vykonávané úlohy
Výstižná reprezentace	Zda reprezentace dat má vhodnou strukturu
Konzistentní reprezentace	Zda jsou data reprezentována vždy ve stejném formátu
Snadnost zpracování	Zda jsou informace snadno zpracovatelné a použitelné pro rozdílné úlohy
Bezchybnost	Zda jsou informace a data přesné a hodnověrné
Interpretovatelnost	Zda je jasná definice informací, zda jsou v odpovídajícím jazyku, jednotkách a zda jsou označeny správnými symboly
Objektivita	Zda jsou informace nestranné a nepředpojaté
Relevantnost	Zda jsou informace použitelné a užitečné pro vykonávané úlohy
Reputace	Zda jsou informace považovány za spolehlivé v souvislosti s jejich zdrojem nebo obsahem
Bezpečnost	Zda omezení přístupu k datům a informacím odpovídá bezpečnostním pravidlům
Včasnost	Zda jsou pro vykonávané úlohy informace k dispozici včas
Srozumitelnost	Zda jsou informace snadno pochopitelné a srozumitelné
Přidaná hodnota	Zda a která data a informace jsou přínosné a jaké jsou výhody jejich použití

Základní otázky datové kvality

- Kdy jsou data kvalitní?
- Kdy jsou data nekvalitní?
- Jak prokázat, že jsou data kvalitní?
- Jak zvýšit kvalitu dat?

- Pozorování
 - Dodavatelé dat obecně nemají moc důvodů produkovat bezchybná data.
 - Nekvalitní data vytváří nesmírnou frustraci uživatelů dat.

- Kvalita dat se nedá dosáhnout pouze prostředky IT.

- Příklady
 - adresa@naznama.cz
 - Rodné číslo

Kdy jsou data nekvalitní?

Perspektiva dat	Perspektiva uživatele	Perspektiva společnosti
Chyba v pravopisu	Informace není dostupná	Rozhodnutí učiněná na základě špatných informací
Duplicitní záznam	Informace je těžko agregovatelná	Drahé a neúčinné marketingové kampaně
Nesprávná hodnota	Informace je nesprávná	Odliv zákazníků díky špatné kvalitě služeb
Zastaralá informace	Na data se nelze spolehnout	Vysoká náročnost nalezení požadovaných informací
Nesprávný formát	Data zachycují jen část celku	Zpoždění projektů implementace nových systémů
Chybějící záznam	Data obsahují logické nekonzistence	Problémy s compliance

Příznaky nekvality v datech?

- Reporty nejdou porovnat
- Pracovníci si vedou soukromé agendy
- Pracovníci si nechávají výsledky kontrolovat

Proč se zabývat datovou kvalitou

- Výskyt chyb v datové kvalitě
- Nespokojenost uživatelů
- Legislativní požadavky, požadavky regulátorů
 - Solvency II
 - Basel II, Basel III

Jak prokázat kvalitu dat?

- Co to je za číslo?
 - Jak vzniklo?
 - Kdo to kontroloval?
 - Byla použita všechna data?
 - Byla použita aktuální data?
- ?????

	Net solvency capital requirement (including the loss-absorbing capacity of technical provisions)	Gross solvency capital requirement (excluding the loss-absorbing capacity of technical provisions)
Market risk	A1	B1
Counterparty default risk	A2	B2
Life un	A3	B3
Health	A4	B4=A4
Non-lif	A5	B5=A5
Diversi	A6	B6
Intangible asset risk	A7	B7=A7

1059,56



Jsou nastaveny procesy a politiky

- Je definována politika datové kvality
- Je definována organizace DQ
 - Role
 - Job description
 - Accountability and responsibility assignment
- Jsou vytvořeny a udržovány slovníky DQ
 - Definice dat
 - Popis dat a datových toků
 - Stanovení metrik datové kvality pro jednotlivé prvky
- Jsou nastaveny procesy DQ
 - Nastaveno měření a reporting datové kvality
 - Nastaven proces řízení chyb v datové kvalitě
 - Identifikace, odhad dopadů, definice nápravy, ohodnocení nápravy, oprava dat, dokumentace opravy
 - Nastaven proces DQ operation

Slovníky datové kvality

Level 3 type	Level 3 definition	Level 3 threshold	Level 4 type	Level 4 - Indicator 1 definition	Level 4 - Indicator 1 threshold
List of values	A pre-defined list of values (1, 2, or I)	0%-2%	Uniqueness	The first 6 variables should uniquely define a record	0%-2%
Format	Numeric format	0%-2%	Uniqueness	The first 6 variables should uniquely define a record	0%-2%
Format	All the dates are yyyy-mm-dd, plus the variable should be within a reasonable			Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
List of values	St			Consistency of values - for different records of the same contract these values should be consistent	0%-2%
List of values	St			Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format				Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
List of values				Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
List of values				Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
Format				Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format				Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format				Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
Format	All			Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format	range	0%-2%	Consistency	Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format	Integer	0%-2%	Consistency	Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format	Integer	0%-2%	Consistency	Consistency of values - for different records of the same contract these values should be consistent	0%-2%
Format	Integer	0%-2%	Consistency	Consistency of values across time - values from previous extract should be consistent with those from the current extract unless there were changes in the contract	0%-2%
Format	Integer	0%-2%	Consistency	Consistency of values across time - values from previous extract should be consistent with those from the current extract unless there were changes in the contract	0%-2%
Format	Number	0%-2%	Consistency	Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
Format	Percentage (a number between 0 and 100)	0%-2%	Consistency	Consistency of values across time - values from previous extract should match with those from the current extract	0%-2%
List of values	A string of 2 characters	0%-2%	Reconciliation	Reconciliation of amounts against the data from other sources, e.g. operations	0%-2%
List of values	A string of 2 characters	0%-2%	Reconciliation	Reconciliation of amounts against the data from other sources, e.g. operations	0%-2%
Format	Number	0%-2%	Reconciliation	Reconciliation of amounts against the data from other sources, e.g. finance	0%-2%

Definice na obchodní úrovni
Definice na technické úrovni
Místo a formát uložení
Vlastník - Zodpovědná osoba
Parametry důležitosti, bezpečnosti, aktuálnosti, ...

Metriky datové kvality

Level 3 t	Level 4 tyj	indicator 1 thresh
List of va	Uniqueness	0%-2%
Forma	Uniqueness	0%-2%
Forma	Consistency	0%-2%
List of va	Consistency	0%-2%
List of va	Consistency	0%-2%
Forma	Consistency	0%-2%
List of va	Consistency	0%-2%
List of va	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
Forma	Consistency	0%-2%
List of va	Reconciliation	0%-2%
List of values	A string of 2 characters	0%-2%
Format	Number	0%-2%
	Reconciliation	Reconciliation of amounts against the data from other sources, e.g. operations
	Reconciliation	Reconciliation of amounts against the data from other sources, e.g. finance

Technické

- Data mají přípustné hodnoty, očekávaný formát, pohybují se v přípustném rozsahu, jsou jednoznačné – pokud je to požadováno, existují odpovídající záznamy v jiných systémech

Významové

- Hodnoty, počty a sumy jsou konzistentní v čase. Porovnání s historickými daty a benchmarky nevykazuje neodůvodněné odchylky.
- Existuje požadovaná konzistence mezi různými záznamy a hodnotami.

Požadavek

- Kontrakt musí mít definován Politiku zajištění

Metrika

- Procento kontraktů s vyplněným parametrem Politika zajištění

Tresholds

- OK > 99%
- Failed < 95 %

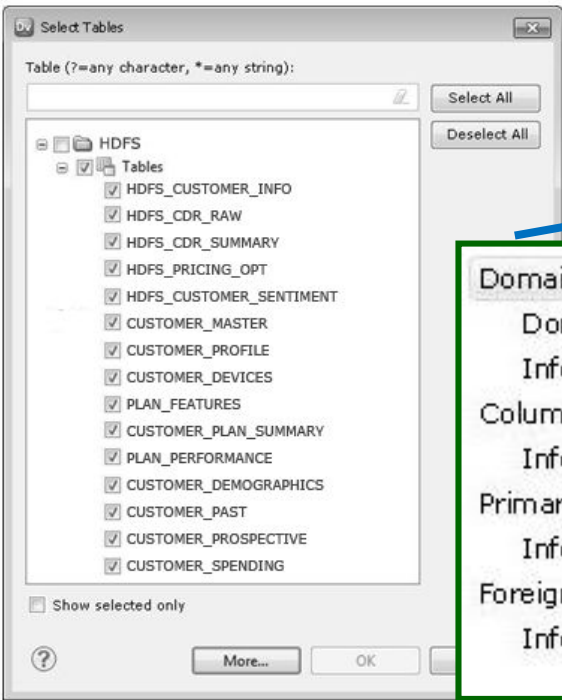
Baseline

- 96,2 %

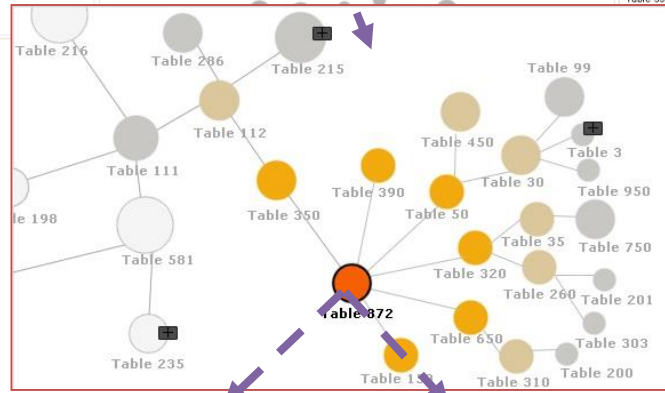
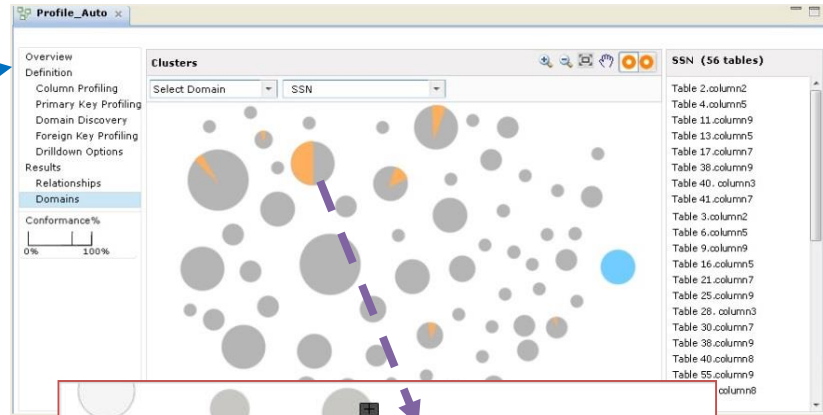
Metriky DQ

- Počet not null hodnot
- Čísla
 - Rozsah
 - Histogram
 - Přesnost
 - Speciální hodnoty (0, 1, 100, 10, ..)
- Řetězce
 - Délka
 - Vzory, hodnoty extrémních vzorů
 - Minimum a maximum
- Vazby
 - Počet nepoužitých cizích klíčů
 - Histogram použití cizích klíčů
 - Počet neexistujících cizích klíčů

Profiling – měření DQ metrik



- Domain Discovery
- Domain Selection
- Inference Options
- Column Profiling
- Inference Options
- Primary Key Profiling
- Inference Options
- Foreign Key Profiling
- Inference Options



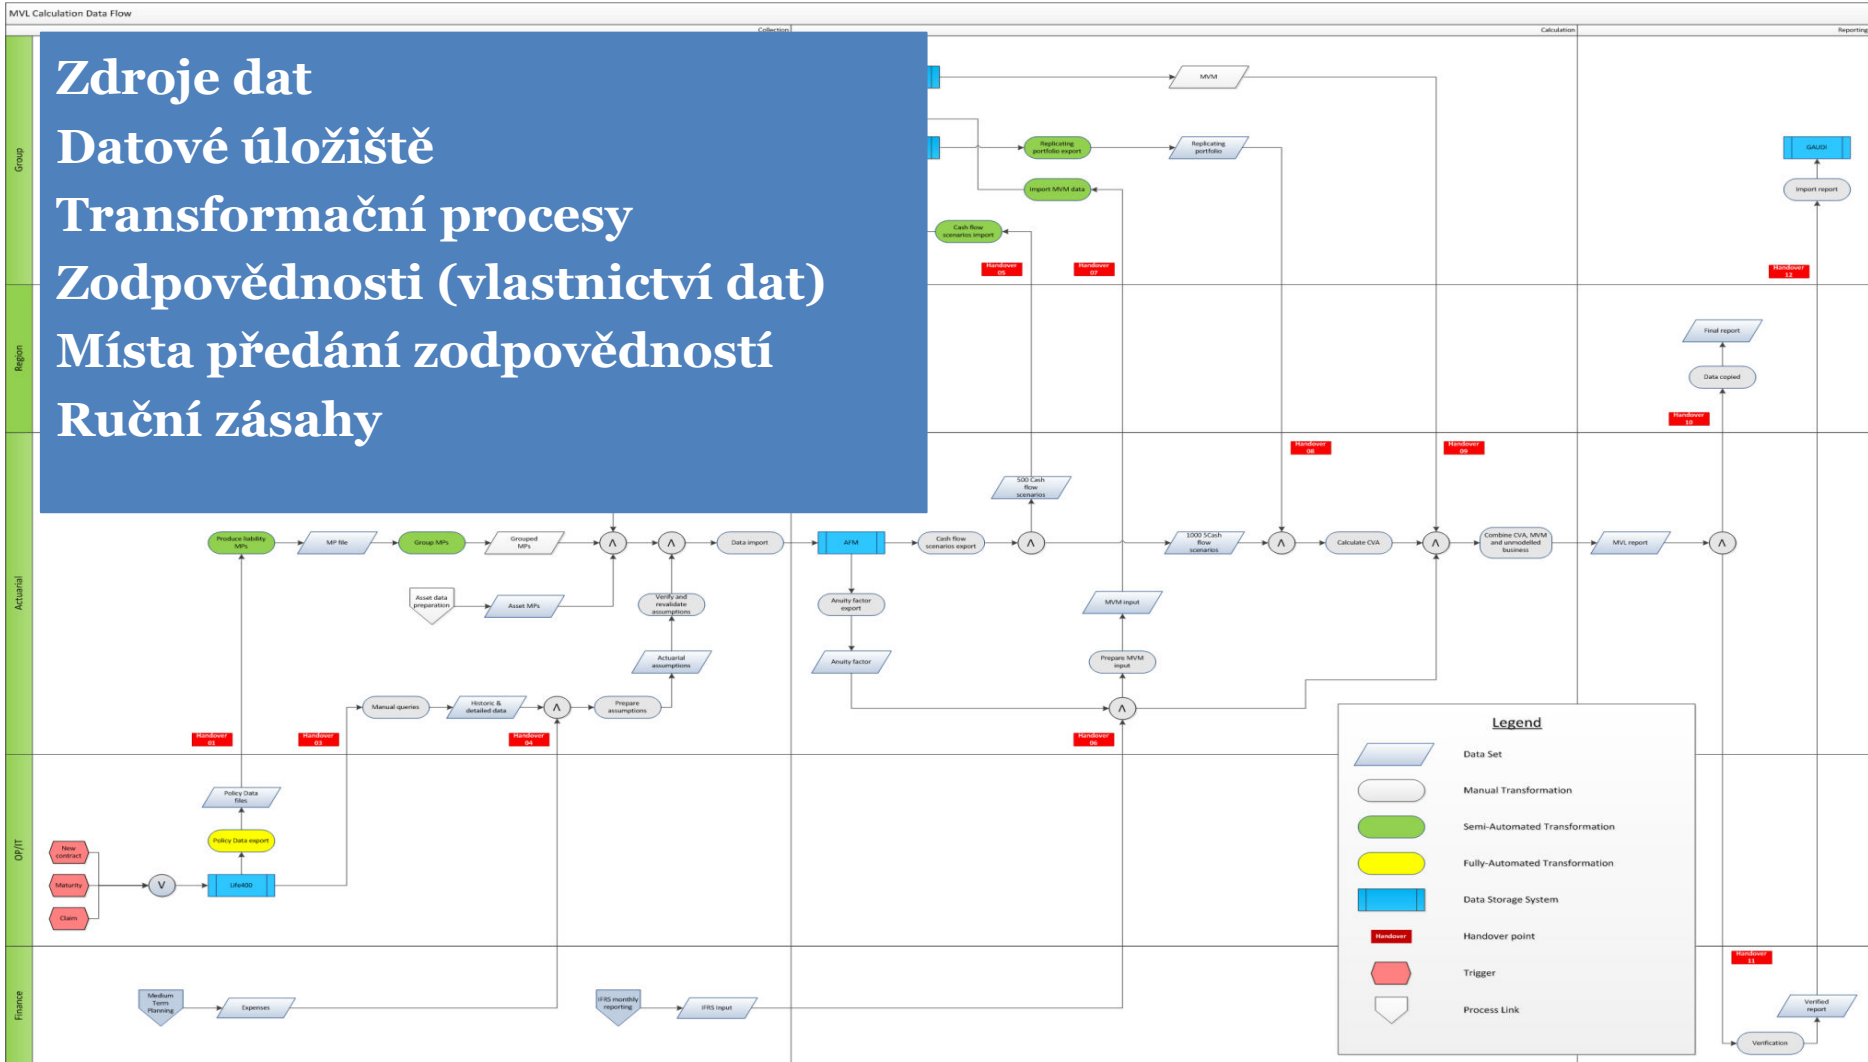
Name	% Data	Column Name...	Fixed In	Domain G...
+	0	Credit Card	88 columns (44 tables)	PCI,PII
+	0	Credit ID	75 columns (25 tables)	PHI
-	0	SSN	88 columns (56 tables)	PHI, PII
+	0	Cluster 5		
	96	Table 2.column2	No	
	96	Table 4.column5	No	
	95	Table 11.column9	No	
	90	Table 13.column5	No	
	94	Table 17.column7	No	
	90	Table 38.column9	No	
	90	Table 40.column3	No	
	79	Table 40.column7	No	
+	0	Cluster 7		
+	0	Cluster 9		
+	0	Cluster 12		
+	0	Cluster 13		

Data Profiling

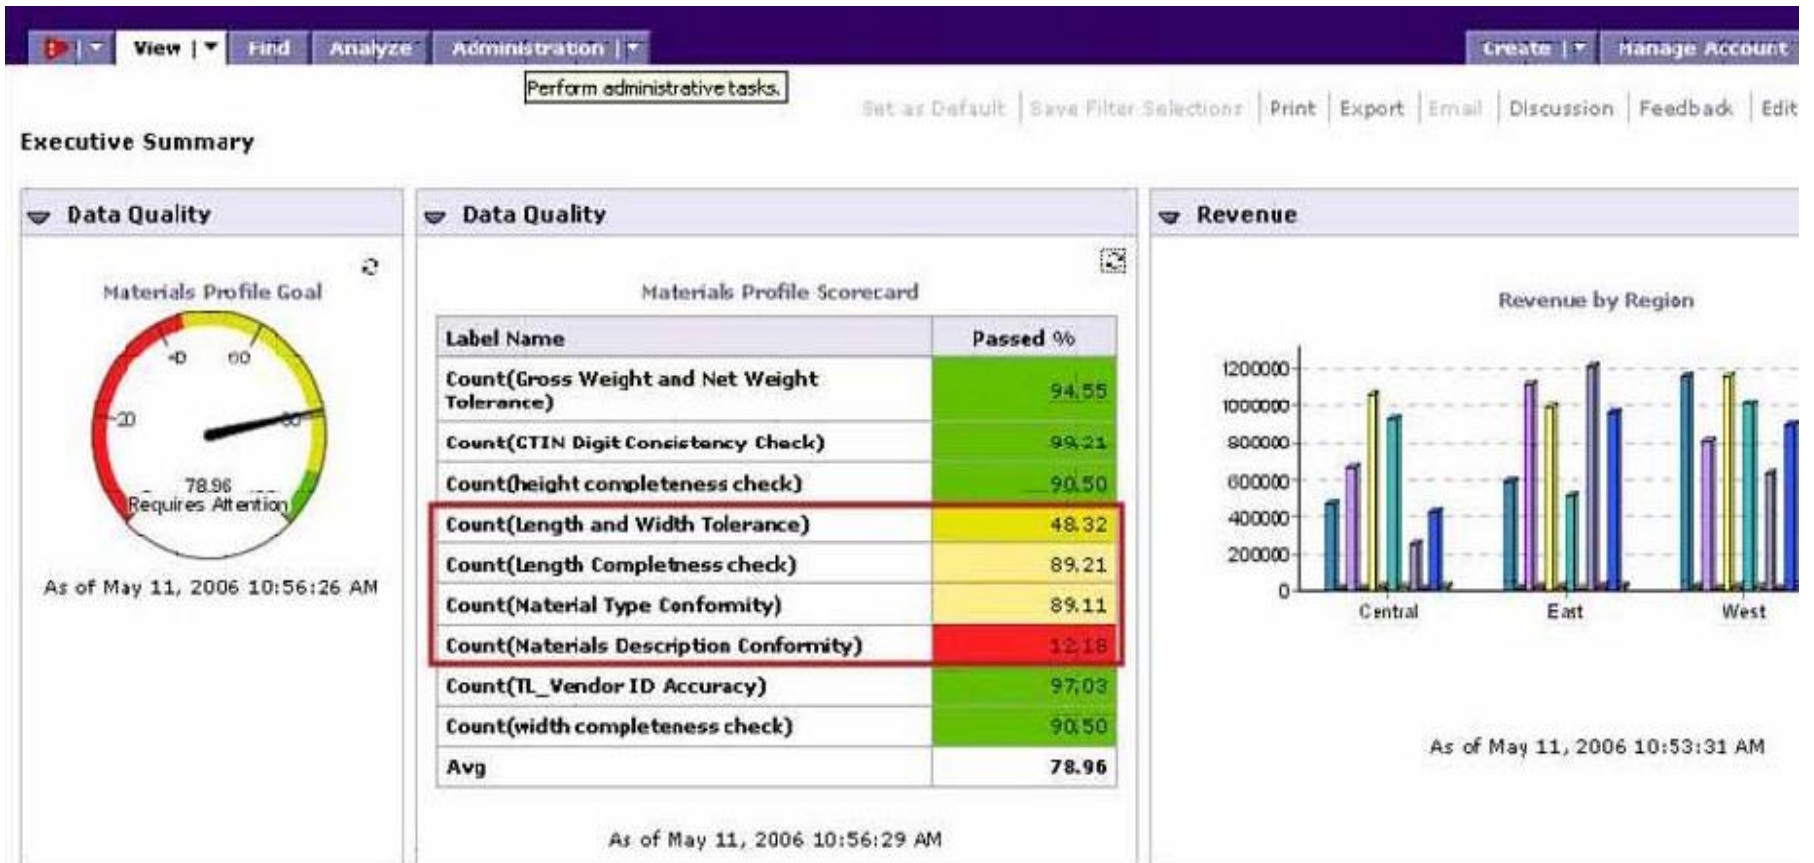
Profile Name: Profile_pmprpf

Name	Pattern	Frequency	Percent
CHDRCOY			
	9	907160	100.0
CHDRNUM			
	999999999	907160	100.0
POANUM			
	XX-X	70225	7.74
	X	836362	92.2
	NULL	321	0.04
	Others	252	0.03
BLABEL			
	X	907160	100.0
AGNTNUM01			
	99999	49070	5.41
	999999	857578	94.53
	NULL	443	0.05
	Others	69	0.01

Popis datových toků

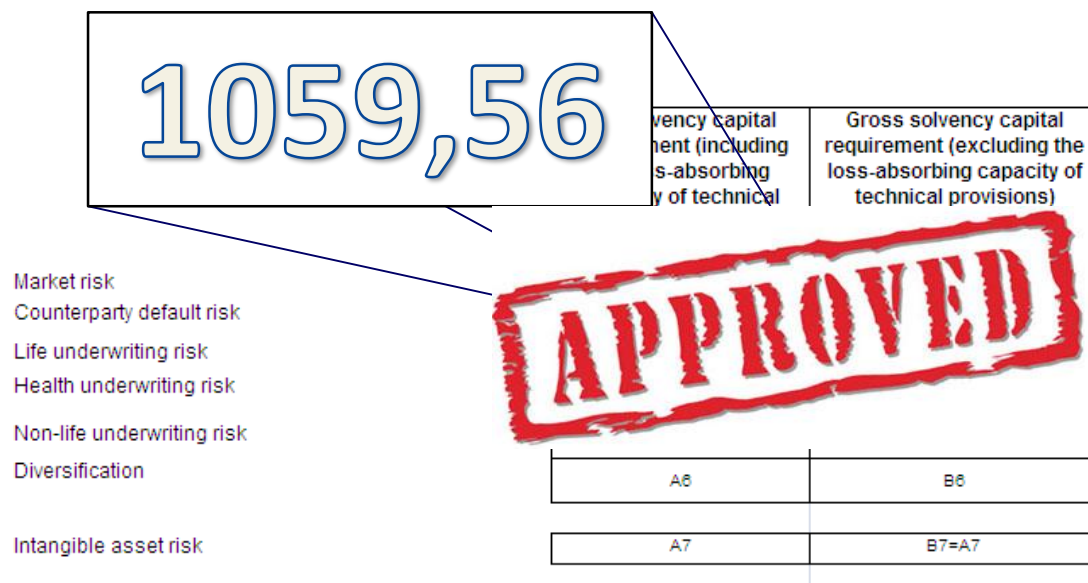


DQ měření a reportování



Jak prokázat kvalitu dat?

- Udělal jsem všechno pro to, abych číslu mohl věřit.



Důvody nekvalitních dat

- Pouze dva zdroje znečištění dat
- Na vstupu
 - Uživatelé
 - Změna zvnějšku, kterou nereflektujeme ve svých systémech
 - Nesprávně provedená migrace dat
 - Špatně nastavená datová integrace
- Zastarávání dat
 - Deset let starý telefonní seznam neobsahuje kvalitní data

Kdy data čistit?

- Vždy je možné „zlepšit“ kvalitu dat
- Pokud si nikdo nestěžuje, nemá smysl investovat zvyšování kvality dat
- Pokud se objeví problém s datovou kvalitou, je třeba porovnávat přínosy a náklady na čištění

Fin. ztráty způsobené nekvalitou dat

- Náklady na dodatečnou verifikaci dat
- Náklady na data re-entry
- Kompenzace
- Pokuty
- Náklady způsobené zhoršenou reputací
- Náklady způsobené špatným rozhodnutím



Náklady na zlepšení datové kvality

- Náklady na školení
- Náklady na pravidelný monitoring
- Náklady na deployment DQ
- Náklady na analýzu
- Náklady na plánování a implementaci opravy

Kdy a jak čistit data

- Vždy je možné „zlepšit“ kvalitu dat
- Pokud si nikdo nestěžuje, nemá smysl investovat zvyšování kvality dat
- Pokud se objeví problém s datovou kvalitou, je nutné porovnávat přínosy a náklady čištění

Jak zvýšit kvalitu dat?

- Čištění dat
 - Neexistuje jedno správné řešení
 - Obecně data nejdou vyčistit
- Čtyři základní metody
 - Nechat kvalitu dat na uživateli – nečistit
 - Jednorázové čištění
 - Čištění příchozích dat
 - Čištění používaných dat
 - Nalezení a úprava znečišťovatele
- Vzdělávání uživatelů a původců dat
- Příklad (voda v jezeře)

Co si zapamatovat


- Co to je datová kvalita
- Jak se pozná, že jsou data kvalitní
- Kdo a jak pozná, že jsou data nekvalitní
- Jaké metody se používají pro čištění dat
- Kde a jak vzniká nekvalita dat
- Co to jsou dimenze datové kvality
- Co to je profiling dat
- Jak se dá prokázat, že jsou informace získaná z dat kvalitní



```

4780 GOTO 5000
4790 :
4800 REM -----
4801 REM --- DARSTELLUNG ---
4802 REM --- DES MANUALS ---
4803 REM -----
4810 :
4820 PRINT"□□";
4825 W=V+1: IF W<0 THEN W=W+14
4830 FOR X=1 TO 2: PRINT"□□□□□□□□□□";
4835 FOR I=0 TO 23
4840 PRINT MD$(I+W);
4850 NEXT: PRINT: NEXT
4860 PRINT"□□□□□□□□□□";
4870 FOR I=0 TO 23
4880 IF MD$(I+W)=CHR$(32) THEN PRINT MB$(
(I+1);: GOTO 4900
4890 PRINT MD$(I+W);
4900 NEXT
4910 PRINT: PRINT"□□□□□□□□□□";
4920 FOR I=2 TO 24 STEP 2
4925 PRINT"!";
4930 IF MD$(I+W-1)="□□ □□" THEN PRINT"□
□";: GOTO 4940
4935 PRINT " ";
4940 NEXT: PRINT"□"
4950 PRINT"□□□□□□□□□□";
4960 FOR I=2 TO 24 STEP 2
4965 PRINT"!";
4970 IF MD$(I+W-1)="□□ □□" THEN PRINT"□"
MB$(I)"□";: GOTO 4980
4975 PRINT MB$(I);
4980 NEXT: PRINT"□"

```



Diskuse

- Otázky
- Poznámky
- Komentáře
- Připomínky

