



Integration Service

# Esercitazione SSIS

ALESSANDRA LUMINI

Alessandra.lumini@unibo.it

<http://tinyurl.com/EsBI2019>

# SQL Server Business Intelligence

Microsoft  
**SQL Server**  
Integration Services

Integrate

- Acquisizione dati da sorgenti e integrazione
- Trasformazione e sintesi dei dati

Microsoft  
**SQL Server**  
Analysis Services

Analyze

- Modellazione dai dati con viste gerarchiche e regole di business
- Data mining

Microsoft  
**SQL Server**  
Reporting Services



Report

- Presentazione e distribuzione dei dati
- Accesso ai dati per le masse


# Cos'è SSIS?

SQL Server Integration Service è piattaforma per la creazione di soluzioni di **integrazione** di dati ad alte prestazioni che consente **l'estrazione**, la **trasformazione** e il **caricamento** di pacchetti (ETL) per il data warehousing

- Offre funzionalità per la gestione di progetti di **Master Data Management**.




# Come funziona SSIS



- Le sorgenti possono essere eterogenee
- Le componenti di trasformazione modificano ed elaborano i dati in molti modi
- La pulizia dei dati si base su regole e condizioni di errore.
- I flussi sono complessi, ma altamente concorrenti
- I dati possono essere caricati in parallelo su diverse destinazioni.

# Architettura SSIS

- SSIS è composto da 2 motori:
  - Workflow engine
  - Data Flow engine




# Componenti di un pacchetto SSIS

- ❑ Flusso di controllo: insieme di componenti per il controllo del flusso dati all'interno di un pacchetto.
  - Inserimento di un controllo "Ciclo" che consenta di ripetere l'operazione di estrazione dati da molteplici sorgenti, evitando la definizione della procedura di esportazione per ogni singola sorgente.
  - Specifica di condizioni per l'esecuzione di particolari attività all'interno del pacchetto.
  - Definizione dell'ordine di esecuzione delle diverse attività che caratterizzano il pacchetto.
- ❑ Flusso dati: insieme delle origini, delle trasformazioni e delle destinazioni dati.
  - Esempi di controlli per la trasformazione dati: unione dati, raggruppamento fuzzy, suddivisione condizionale.

# Componenti di un pacchetto SSIS


- ❑ Gestione connessioni: componente per la definizione della connessione alle sorgenti e destinazioni dati (es. Flat file, origine OLE DB).
- ❑ Variabili: utilizzate per aggiornare dinamicamente i valori di proprietà all'interno di un pacchetto o per gestire funzioni di controllo (es. variabile di ciclo).
- ❑ Gestore eventi: componente per la gestione degli eventi generati durante l'esecuzione di pacchetti SSIS.
- ❑ Provider log: gestisce informazioni di supporto (log) relative all'esecuzione di pacchetti SSIS (es. data/ora di esecuzione, elenco attività).

# Flusso di controllo



# Flusso di controllo


- ❑ Contenitori: definiscono la struttura del flusso di controllo, raggruppando attività e definendo operazioni cicliche:
  - **Ciclo For**: ripete il flusso di controllo finché un'espressione specificata non risulta falsa.
  - **Ciclo Foreach**: enumera un insieme di entità e ripete il flusso di controllo per ogni elemento dell'insieme.
  - **Sequenza**: consente di definire dei sottoinsiemi di attività e contenitori e considerarli come unità atomiche.




# Flusso di controllo

- ❑ Attività: elementi che eseguono i controlli definiti nel flusso dati; di seguito alcune possibili attività:
  - **Attività Flusso Dati**: specifica di origini, trasformazioni e destinazioni dati.
  - **Attività di Preparazione Dati**: copia di file, esecuzione di operazioni su file XML.
  - **Attività di Scripting**: definizione di procedure personalizzate per estendere le funzionalità dei pacchetti SSIS.
  - **Attività di manutenzione**: esecuzione di funzioni di amministrazione (es. procedure di backup su database SQL).
- ❑ Vincoli di precedenza: rappresentano dei connettori fra le attività e i contenitori di un pacchetto (flusso di controllo ordinato).

# Flusso dei Dati



# Flusso dati



- ❑ Origine dati: controlli che permettono l'estrazione dei dati dalle sorgenti (es. Flat file, OLE DB, SQL server database).
- ❑ Trasformazioni: controlli per la definizione di trasformazioni sui dati.
- ❑ Destinazione dati: controlli per la memorizzazione dei dati trasformati sulle opportune destinazioni.

# Trasformazioni

- ❑ Ricerca (Lookup)
  - ❑ Ricerca Fuzzy (Fuzzy Lookup )
  - ❑ Raggruppamento Fuzzy (Fuzzy Grouping)
  - ❑ Unione input multipli
  - ❑ Suddivisione condizionale
  - ❑ Merge join
  - ❑ Colonna derivata
- 
- ❑ Ordinamento: dei record di input
  - ❑ Aggregazione: aggregazione dei dati di input
  - ❑ Estrazione termini: estrazione di termini da campi testuali
  - ❑ Conversione dati: trasformazione di tipo dei dati in input


# Ricerca (Lookup)

- ❑ Esegue ricerche unendo in join (**equi-join**) i dati contenuti nelle colonne di input e le colonne in un set di dati di riferimento.
- ❑ Individua corrispondenze **esatte**.
- ❑ I record di input per cui non viene trovata alcuna corrispondenza, vengono gestiti come errori.
- ❑ In caso di corrispondenze multiple, viene mantenuta la prima corrispondenza individuata.
- ❑ I dati di riferimento devono essere memorizzati all'interno di un'**origine dati OLE DB**.



# Ricerca Fuzzy (Fuzzy Lookup)

La Ricerca Fuzzy esegue attività di pulitura dei dati (es. standardizzazione, correzione e inserimento di valori mancanti)



# Ricerca Fuzzy (Fuzzy Lookup)

## □ Reference table:

- Deve essere una tabella memorizzata all'interno di un database di SQL Server (versione 2000 o successive).
- I campi su cui viene applicata una corrispondenza fuzzy devono essere di tipo DT\_WSTR o DT\_STR.

## □ Parametri di input:

- Numero massimo di corrispondenze: numero massimo di record simili da restituire per ciascun record di input.
- Soglia: valore minimo di similarità affinché il record di input sia valutato come simile ad un record della reference table.
- Delimitatori: delimitatori utilizzati per la suddivisione dei record in token (es. , ; .)

# Ricerca Fuzzy (Fuzzy Lookup)

## □ Algoritmo di confronto

- Error-Tolerant Index (ETI): suddivide ciascun record in token o parole (la suddivisione avviene in base alla scelta di opportuni delimitatori).

Stringa

Tokens

13831 N.E. 8th St

13831, N, E, 8th, and St

(delimitatori: spazio, punto)

- L'algoritmo confronta i token del record di input con i token presenti nella reference table.
- La similarità fra token viene calcolata tenendo conto di:
  - Edit Distance a livello di token
  - Ordinamento dei token
  - Numero token simili
- La similarità è calcolata nell'intervallo [0,1].
- È possibile specificare un insieme limitato di campi del record su cui eseguire il confronto.

# Ricerca Fuzzy (Fuzzy Lookup)

- ❑ Output: è costituito da un insieme di campi che comprendono:
  - Il sottoinsieme di campi del record di input, i campi della reference table, valori di similarità e confidenza.
    - **Similarità**: grado di somiglianza tra i valori dei campi di input (record di input) e di riferimento (record reference table).
    - **Confidenza**: probabilità con cui un valore specifico risulta essere la corrispondenza migliore tra le corrispondenze individuate nella tabella di riferimento.

# Raggruppamento Fuzzy (Fuzzy grouping)

- ❑ Consente di eseguire operazioni di pulizia sui dati.
- ❑ Permette l'individuazione di eventuali duplicati e la creazione di un insieme di record standardizzati e ripuliti.
- ❑ Per la ricerca dei duplicati e dei record “rappresentanti” si basa sull'algoritmo Fuzzy Lookup.
- ❑ Non viene utilizzata una ReferenceTable, ma i record “rappresentanti” vengono scelti fra le righe dell'input.

# Fuzzy grouping

## □ Parametri di input:

- Soglia: valore minimo di similarità affinché il record di input sia valutato come simile ad un record riferimento.
- Delimitatori: utilizzati per la suddivisione dei record in token (es. , ; .).

## □ Algoritmo di confronto:

- A ciascun record di input viene associato un identificatore `key_in`.
- Il sistema deriva (tramite algoritmo interno) un insieme di record “rappresentanti”.
- Utilizza l’algoritmo Fuzzy Lookup per l’individuazione dei duplicati.
- Al termine dell’algoritmo, il sistema ha individuato un insieme di record di riferimento e un insieme di potenziali record duplicati per ciascun record di rappresentante.
- A ciascun record viene aggiunto un campo `key_out` che identifica il gruppo di appartenenza, ovvero memorizza l’identificatore univoco (`key_in`) del record rappresentante a cui il record in esame risulta simile.

# Fuzzy grouping

## □ Output:

- I campi del record di input.
- Similarità: grado di somiglianza tra i valori dei campi di input (record di input) e i campi del record di riferimento (record reference table).
- Score: grado di somiglianza complessivo fra il record di input e il record di riferimento.
- Valori di `key_in` e `key_out`.



↑  
Identificatore univoco

↑  
Identificatore del gruppo di appartenenza (key\_in del record di riferimento)

I record riferimento hanno `key_in=key_out`

# Unione input multipli (Union all)

Consente di combinare più input in un unico output (es. è possibile utilizzare gli output di cinque diverse origini dati come input e combinarli in un singolo output).

- Gli input della trasformazione vengono aggiunti all'output della trasformazione uno dopo l'altro, senza riordinare le righe.
- Vengono inseriti valori nulli per i campi mancanti.

# Suddivisione condizionale (Conditional split)

- ❑ Distribuisce i record di input in diverse destinazioni a seconda dei criteri di suddivisione impostati (analogo ad un'istruzione di programmazione *switch*), per utilizzarlo è necessario:
  - Specificare uno o più condizioni da verificare durante la trasformazione.
  - Specificare l'ordine di valutazione delle condizioni.
  - Specificare l'output predefinito per i record che non soddisfano alcuna condizione.
  
- ❑ Applicazione:
  - Suddividere i record risultanti da una trasformazione di raggruppamento fuzzy per categorie di similarità.
  - Categorizzare i dati di input (es. classificazione dei clienti in differenti categorie di fedeltà al negozio, basandosi sui dati degli acquisti del cliente, risultanti da una procedura di integrazione).

# Merge Join

- ❑ Consente di definire il join fra record di due insieme di dati **ordinati sulle chiavi di join.**
- ❑ Tipi di join supportati:
  - Full outer join
  - Left outer join
  - Inner join

# Colonna derivata (Derived column)

- ❑ Consente di creare nuovi valori di colonna tramite l'applicazione di espressioni alle colonne di input della trasformazione.
- ❑ Applicazione:
  - In caso di record duplicati, si possono definire delle colonne derivate per stabilire quale valore associare ai campi per cui non esiste un valore univoco.
  - Sostituzione di valori mancanti.
  - Definire una priorità fra i valori dei campi di record diversi.

# Preparazione alle esercitazioni

- Aprire Visual Studio Creare nuovo Progetto: Integration Services Project
- Per le connessioni di tipo OLE DB utilizzare il seguenti parametri:
  - Server: ISI-SQLNEW
  - Database: SISSLab

# Esempio 1- Ricerca

- Specifiche:
  - Estrarre i record da due sorgenti distinte. I dati riguardano le vendite eseguite in stati diversi (USA e Canada). Ciascun record di vendita contiene anche il riferimento al prodotto oggetto della transazione. Il sistema dispone di un'anagrafica centralizzata dei prodotti in vendita. Si vuole verificare che i codici dei prodotti venduti abbiano una corrispondenza in anagrafica e fondere i dati in un'unica tabella.

## VENDITE USA

IDPRODUCT;IDSALES

1;0011

2;0031

3;0050

4;0014

5;0037

6;0037

7;0037

## VENDITE CANADA

IDPRODUCT;IDSALES

148;0001

882;0088

891;0150

1302;0001

1428;0043

103;0100

503;0101

503;0100

3;0100

## ANAGRAFICA PRODOTTI

IDPRODUCT

1

2

148

891

1302

1428



503

103

# Esempio 1

- **Competenze:**
  - Estrazione dati da più sorgenti.
  - Trasformazione Unione Multipla e Ricerca.
  - Gestione del flusso di errore.
  - Impostazione Sorgenti e Destinazioni.
- **Traccia di soluzione:**
  - Trasferire il file dei prodotti su DB
  - Unire i dati di input.
  - Confrontare i dati di input (vendite) con quelli presenti in una tabella di riferimento (anagrafica prodotti). Si ricercano corrispondenze esatte fra i record basandosi sul codice prodotto.
  - Gestire il flusso di errore per i record per cui non è stata trovata alcuna corrispondenza.
  - Creare una nuova tabella di database contenente i record per cui è stata individuata una corrispondenza.

# Esempio 1- Soluzione



# Esercizio 2 - Integrazione anagrafiche clienti

- Specifiche:
  - Integrare le anagrafiche clienti memorizzate da diverse reparti aziendali (vendite, call center, marketing) e individuare possibili record duplicati.

## CUSTOMERS CALL CENTER

ID	FirstN	MiddleI	LastName
4	Patty	T	Arun
1	Mary	A	Jane
10	Carl	R	Shor
11	Bridget		Bhat
105	Caleb		Bryan
11	Mitchell	D	Raji
128	Matthew		Thompson
1302	Logan		Simmons


## CUSTOMERS MKT

## CUSTOMERS SALES

# Esercizio 2- Integrazione anagrafiche clienti

- Competenze:
  - Estrazione dati da più sorgenti.
  - Trasformazione Unione Multipla, Raggruppamento Fuzzy, Suddivisione Condizionale.
  - Impostazione Sorgenti e Destinazioni.
- Traccia soluzione:
  - Unire i dati di input.
  - Applicare un raggruppamento Fuzzy per l'individuazione dei duplicati (soglia 0.8)
  - Applicare una suddivisione condizionale per distinguere i dati standardizzati (puliti) dai potenziali duplicati. (`_key_in == _key_out` → puliti)
  - Memorizzare dell'output della suddivisione condizionale in corrispondenti tabelle di database SQL Server (generazione automatica).

# Esercizio 2- Soluzione



# Esercizio 3- Integrazione dati e aggiornamento campi


- Specifiche
  - Si vogliono integrare le anagrafiche clienti dei reparti vendite e mkt.
  - Le due anagrafiche memorizzano gli stessi clienti (congruenza fra ID), ma con diversi livelli di aggiornamento dai dati contenuti. Si vuole creare un'unica anagrafica contenente tutti i clienti e i dati aggiornati. In particolare:
    - MaritalStatus: è prevista una marca temporale per questo attributo. Si mantiene il valore più recente;
    - Phone: se presente si mantiene il valore specificato nell'anagrafica clienti del reparto MKT, altrimenti quello dell'anagrafica vendite;
    - Per tutti gli altri dati si mantengono i valori delle vendite;

ID	FirstName	MiddleInitial	LastName	ValidityDate	MaritalStatus	EmailAddress	Address	City	State	Phone
1	Abby	C	Malhotra	12/11/2000	M	amalhotra@thepho...	1019 Carletto Drive	Sedro Woolley	WA	645-555-...
2	Abby		Prasad	08/06/1952	S	aprasad@blueyond...	3261 Vista Bonita	Concord	CA	
3	Abby		Srini	20/4/1961	M	asrini@adatum.com	9191 Camelback Ct.	Berkeley	CA	827-555-...
4	Abby	E	Rodriguez	05/05/1951	M	arodriguez@fabrika...	6753 Howard Hugh...	Las Vegas	NV	1 (11) 50...
5	Abigail		Brown	03/05/1946	M	abrown@treyresear...	4710 Northridge Drive	Port Orchard	WA	155-555-...
6	Abigail	A	Watson	21/7/1972	S	awatson@thephone...	8757 Keith Court	Seattle	WA	1 (11) 50...
7	Abigail	C	Bryant	06/09/1977	M	abryant@northwind...	2639 Anchor Court	Edmonds	WA	
8	Abigail	C	Hall	24/6/1972	S	ahall@northwindtra...	8036 Summit View Dr.	Gold Bar	WA	
9	Abigail		Davis	22/12/1955	S	adavis@fabrikam.com	70 N.w. Plaza	Saint Ann	MO	1 (11) 50...
10	Abigail	F	Florez	27/1/1952	M	aflorez@baldwinmu...	867 Maria Vega Court	Colma	CA	652-555...

# Esercizio 3- Integrazione dati e aggiornamento campi


- Competenze:
  - Estrazione dati da due sorgenti.
  - Trasformazione Merge Join, Colonna derivata.
- Traccia di soluzione
  - Ordinare i dati di input sul campo ID.
  - Applicare un merge Join per fondere i due file (Inner join).
  - Utilizzare una colonna derivata per la selezione dei campi **MaritalStatus** e **Phone** in base alle specifiche (Usare nvarchar per le nuove colonne per evitare problemi di conversione)
    - `ValidityDate > ValidityDate_MKT ? MaritalStatus : MaritalStatus_MKT`
    - `!ISNULL(Phone_MKT) ? Phone_MKT : Phone`
  - Memorizzare dell'output in una nuova tabella di database SQL Server.

# Esercizio 3- Soluzione



# Esercizio 4: MDM coesistenza

- Si vuole progettare una architettura per MDM in cui un hub centrale (CLIENTI\_GLOBAL) mantiene una versione aggiornata dei dati caricati dalle sorgenti (CLIENTI Sorgente 1 e CLIENTI Sorgente 2).
- Il progetto consiste nella definizione di 2 flussi dati sulla base di criteri dati:
  1. Caricamento quotidiano dei clienti modificati nella sorgente 1 sull'hub
  2. Aggiornamento asincrono dei dati della sorgente 2 a partire dall'hub
- **NOTA:** il join tra sorgenti e hub è fatto della base della similarità ( $\sigma > 0.8$ ) del campo NOMINATIVO. In caso di confidenza minore di 1 l'aggiornamento deve essere manuale
- **Gestione degli identificatori univoci (campo ID)**
  - Quando viene inserito un nuovo record sull'hub oppure sulle sorgenti è necessario generare un nuovo ID (autoincremento)



# Dati di input

## CLIENTI\_GLOBAL

<b>ID</b>	<b>NOMINATIVO</b>	<b>PROFESSIONE</b>	<b>TELFISSO</b>	<b>DATARECORD</b>
01	Mario Rossi	MANAGER	054214785	2011-11-13
02	Mario Neri	MANAGER	054214785	2011-06-24
03	Mauro Nero	IMPIEGATO	05463256	2011-11-04
04	Anna Verdi	IMPIEGATO	05442356	2011-11-05
05	Anna Verde	SEGRETARIA	054785236	2011-01-17
06	Anna Vardi	MANAGER	05489632	2011-02-07

## CLIENTI Sorgente 1

<b>ID</b>	<b>NOMINATIVO</b>	<b>PROFESSIONE</b>	<b>DATARECORD</b>
01	Elisa Turrichia	STUDENTE	2011-11-25
02	Mario Rossi	IMPIEGATO	2011-11-10
03	Mario Neri	IMPIEGATO	2011-11-25
04	Anna Verdi	DIRETTORE	2011-11-25

## CLIENTI Sorgente 2


<b>ID</b>	<b>NOMINATIVO</b>	<b>TELFISSO</b>	<b>PROFESSIONE</b>	<b>DATARECORD</b>
04	Mario Rossi	054214785	MANAGER	2011-11-13
01	Anna Verde	054785236	SEGRETARIA	2011-11-01

# Criteri di aggiornamento dei dati

- SORGENTE 1 → HUB
  - Dalla sorgente vengono estratti tutti i record con DATARECORD uguale alla data odierna
  - Nuovo cliente → inserimento di un nuovo record nell'hub
  - Cliente preesistente → l'aggiornamento avviene se è stata eseguita una modifica sul campo PROFESSIONE
  
- HUB → SORGENTE2
  - Vengono estratti tutti i record dell'hub
  - Nuovo cliente → inserimento di un nuovo record nella sorgente
  - Cliente preesistente → l'aggiornamento avviene se il record dell'hub è più recente di quello della sorgente

# Soluzione: flusso di controllo

```
UPDATE [Sorgente1]  
SET DATARECORD =  
CONVERT(date,  
SYSDATETIME())  
WHERE ID>2
```



# Creazione tabelle


```
CREATE TABLE [Sorgente1](  
    [ID] int IDENTITY(1,1),  
    [NOMINATIVO] [varchar](50) NULL,  
    [PROFESSIONE] [varchar](50) NULL,  
    [DATARECORD] date NULL  
)
```

```
CREATE TABLE [Hub](  
    [ID] int IDENTITY(1,1),  
    [NOMINATIVO] [varchar](50) NULL,  
    [PROFESSIONE] [varchar](50) NULL,  
    [DATARECORD] date NULL,  
    [TELFISSO] [varchar](50) NULL  
)
```

Settare a true il flag  
KEEP IDENTITY nel  
mapping

# Soluzione: Flusso dati S1 → Hub

Condizione sulla data:  
DATA RECORD=  
CONVERT(date, SYSDATETIME())



UPDATE [HUB] set  
professione=?,  
datarecord=? WHERE  
ID= ?

# Soluzione: Flusso dati Hub → S2

