

The Generic Statistical Information Model (GSIM) and the Sistema Unitario dei Metadati (SUM): state of application of the standard

Cecilia Casagrande – casagran@istat.it

21 settembre 2016

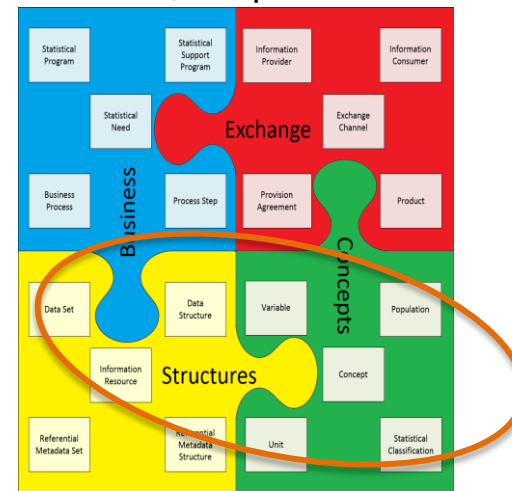
- Generic Statistical Information Model (GSIM) and Istat metadata system (SUM)
- The Istat metadata system SUM
 - Population, variable and other concepts
 - Classification
 - Data content
 - Data structures
- Functionalities, developments and benefits
 - Search functionalities
 - Implementation of GSIM
 - Benefits and more

GSIM and Istat metadata system (SUM)

GSIM describes the “interfaces” in terms of subprocesses input and output, leaving to GSBPM the description of the subprocesses



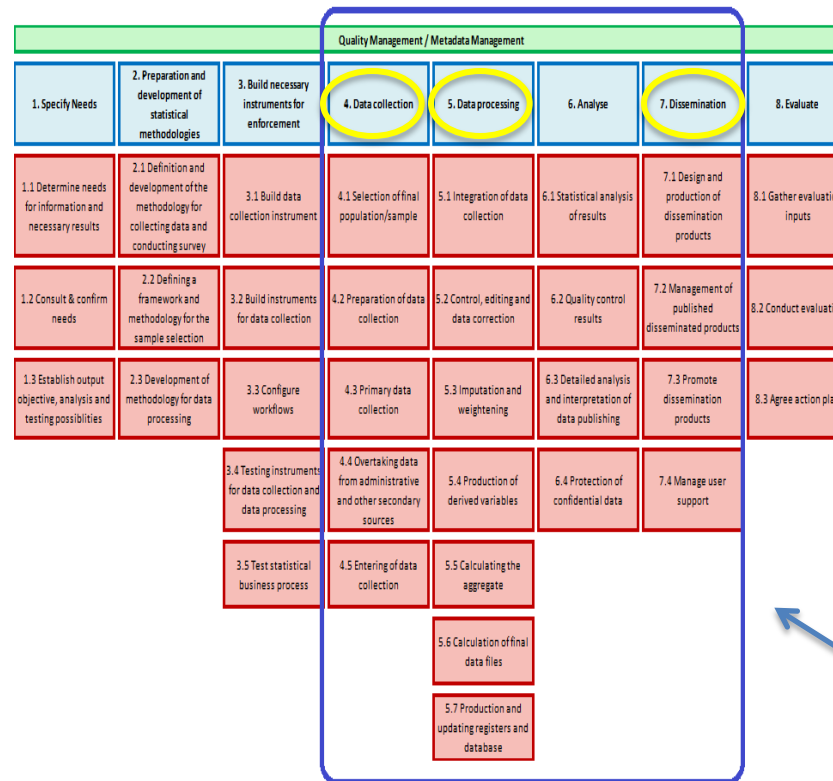
1. In order to trace the data production process, Istat metadata system considered GSIM as a primary source of information.
2. Our current objective is to develop the part of Istat metadata system (SUM) related to data (structural metadata).
3. Hence, attention has been given mostly to a portion of GSIM, the part related to the “structure” and “concepts”



4. Istat metadata system SUM is coherent with GSIM for definitions and nomenclatures

The Istat metadata system SUM

- The Istat metadata system (SUM) is a centralized system which contains structural metadata. SUM aims to describe data and data connections able to trace the data production process from data collection (raw data) up to data dissemination.



The system should aim at easing:

Harmonization: our Institute should speak using the same **terms** according to a common language **structure**, independently on the theme

Reuse: new processes should draw terms among those already existing

Search functionalities: in order to foster harmonization and reuse, there should be adequate search functionalities

Traceability: every step of the data production process is operationally defined so to allow reconstruction of the same data from another party (transparency)

Rilascio in via sperimentale del Sistema Unitario dei Metadati



Il Sistema Unitario dei Metadati, nella sua componente relativa ai metadati strutturali, viene rilasciato in via sperimentale nella intranet di Istituto con un primo pacchetto di [funzionalità](#), e a un livello di popolamento parziale (copertura al 100% dei metadati relativi alla fase di diffusione tramite I.Stat, inizio del popolamento dei metadati relativi alle fasi di acquisizione dati e validazione). Durante il primo semestre 2016 il sistema verrà arricchito di nuove funzionalità e ulteriormente popolato. Chiunque riscontri errori nei contenuti del sistema o voglia proporre funzionalità specifiche non ancora presenti nel sistema e utili per le attività di Istituto, può contattare il gruppo SUM all'indirizzo email: sum@istat.it.

Descrizione del sistema

La strategia di modernizzazione e di industrializzazione dei processi statistici dell'Istituto, nota con il nome di Stat2015, ha tra i suoi pilastri la gestione unitaria dei metadati statistici attraverso il Sistema Unitario di Metadati - SUM.

Il progetto complessivo, da realizzare per step successivi entro il 2015, si basa su di una visione unitaria ed integrata di tutte le tipologie di metadati:

- **Strutturali:** metadati che definiscono il significato di ogni dato statistico prodotto dall'Istat. Nel SUM è quindi possibile ritrovare le unità di riferimento dei (micro o macro) dati, i nomi delle variabili statistiche o di altri concetti, le classificazioni statistiche e altre tipologie di liste, gli indicatori statistici prodotti, oltre alla descrizione completa dei contenuti dei dataset di micro e macro dati.
- **Referenziali:** metadati che definiscono il contenuto e la qualità dei dati statistici prodotti dall'Istat. Questa parte del sistema contiene le metainformazioni relative ai processi produttivi statistici (rilevazioni, elaborazioni e sistemi informativi) e ai processi secondari (moduli ad hoc, ampliamenti del campione, indagini pilota e indagini di controllo della qualità o sperimentazioni) condotti dall'Istat. (vedi SIDI-SIQUAL)

Navigazione del sistema

- » [SUM-MS] Metadati strutturali: variabili, classificazioni, strutture dati
 - » Tesauri e liste [Backend]
 - » Tesauri e liste : liste di variabili, collettivi statistici, concetti temporali
 - » Classificazioni
 - » Strutture dei dati
 - » Tracciabilità dei metadati [Backend]
 - » SDMX Registry

» Logout

Population

Hierarchical relationship

ID Operatore: casagran
 Profilo: Supervisore
 Version 2.5 - 25 Febbraio 2016

SUM SISTEMA UNITARIO METADATI

Home **Unità statistiche** Variabili statistiche e concetti Altre liste Indicatori statistici Logout

Elenco delle Unità statistiche

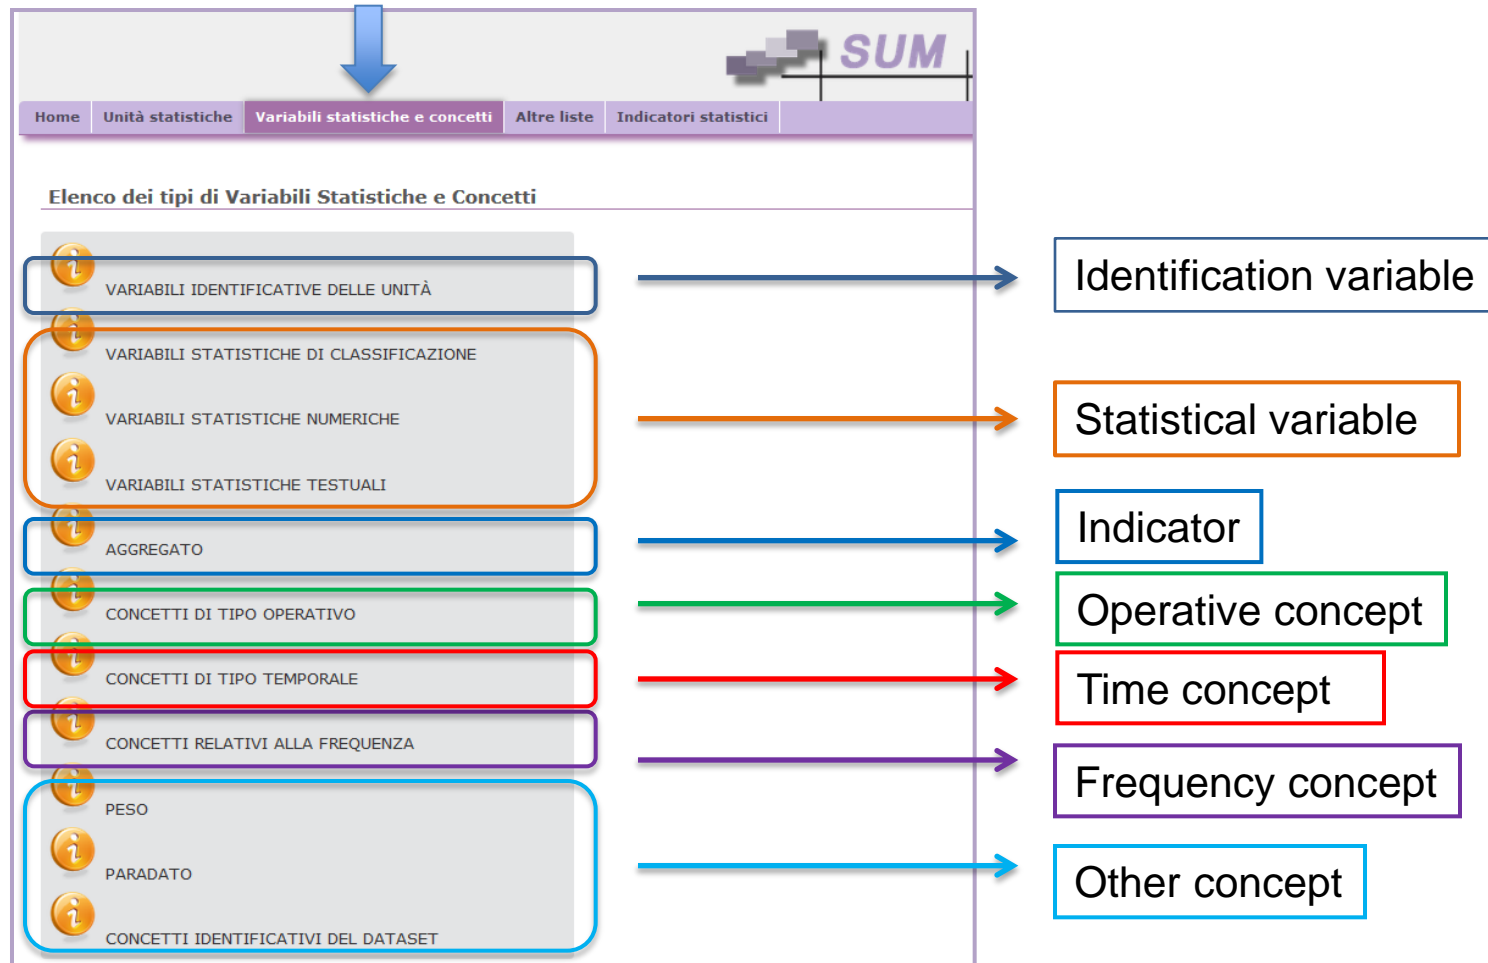
donne

Totale delle unità statistiche: 1109
 Totale delle unità statistiche coinvolte in indagini: 311

ID	Nome	Definizione	Padre	Numero Indagini
754	Donne 14-59 anni			
DONNE16_70	Donne 16-70 anni		Individui	
DONNE_IVG	Donne che si sono sottoposte a IVG			1
184	Donne che si sottopongono all'interruzione volontaria di gravidanza			
3512	Donne che vivono in coppia			
3551	Donne di 25 anni o più			
3511	Donne non nubili e uomini vedovi			
DONNE_RES15_49	Donne residenti 15-49 anni		Popolazione residente	
DONNE_RES_15	Donne residenti di 15 anni di età		Donne residenti 15-49 anni	
DONNE_RES_16	Donne residenti di 16 anni di età		Donne residenti 15-49 anni	
DONNE_RES_17	Donne residenti di 17 anni di età		Donne residenti 15-49 anni	
DONNE_RES_18	Donne residenti di 18 anni di età		Donne residenti 15-49 anni	
DONNE_RES15_17	Donne residenti di età 15-17 anni		Donne residenti 15-49 anni	
DONNE16_70_PART	Donne tra i 16 e i 70 anni che hanno o hanno avuto un partner		Donne 16-70 anni	
IVG15_17	Interruzioni volontarie della gravidanza di donne residenti 15-17 anni		Interruzioni volontarie di gravidanza	
NATIVIVI_DRES_15	Nati vivi da donne residenti di 15 anni		Nati vivi da donne residenti di età 15-49 anni	
NATIVIVI_DRES_16	Nati vivi da donne residenti di 16 anni		Nati vivi da donne residenti di età 15-49 anni	
NATIVIVI_DRES_17	Nati vivi da donne residenti di 17 anni		Nati vivi da donne residenti di età 15-49 anni	
NATIVIVI_DRES_18	Nati vivi da donne residenti di 18 anni		Nati vivi da donne residenti di età 15-49 anni	
NATIVIVI_DRES15_49	Nati vivi da donne residenti di età 15-49 anni		Nati vivi	

Esporta dati: | |

Variable



Classification

The screenshot displays the SUM (SISTEMA UNITARIO METADATI) web application interface. The browser address bar shows the URL: `sum.istat.it/SUM/secure/classificazioni/inputElencoFamiglie.action`. The page header includes the SUM logo and the text "SISTEMA UNITARIO METADATI". On the right side of the header, the user information is displayed: "ID Operatore: casagran", "Profilo: Supervisore", and "Version 1.0 - February 19, 2015".

The main navigation menu contains the following items: "Home", "Visualizzazione Classificazioni", "Gestione Classificazioni", "Ricerca Testuale", and "Logout".

The main content area is titled "Classificazioni per famiglia" and displays a hierarchical list of classification categories. The categories are:

- Agricoltura
- Ambiente ed energia
- Assistenza e previdenza
- Classificazioni di supporto (tempo, confronto, giudizi)
- Condizioni economiche delle famiglie e disuguaglianze
- Cultura, comunicazione e tempo libero
- Giustizia e sicurezza
- Imprese, conti nazionali e commercio con l'estero
- Lavoro
- Partecipazione sociale
- Popolazione e abitazioni
- Pubblica amministrazione
- Salute e sanità
- Scuola e università
- Territorio e classificazioni geografiche
- Trasporti
- xx Altre liste
- xx Da riallocare

The "Territorio e classificazioni geografiche" category is expanded, showing a sub-list of classifications:

- Classificazione Area di provenienza
- Classificazione Geopolitica e Stati Esteri
- Classificazione Lista delle comunità montane
- Classificazione Livello territoriale
- Classificazione Sistema di proiezione
- Classificazione Sistema locale del lavoro del 2001
- Classificazione Territorio
- Classificazione Tipo di coordinate
- Classificazione Tipo territorio
- Classificazione Zona
- Classificazione Zona altimetrica
- Classificazione Zona provenienza o destinazione

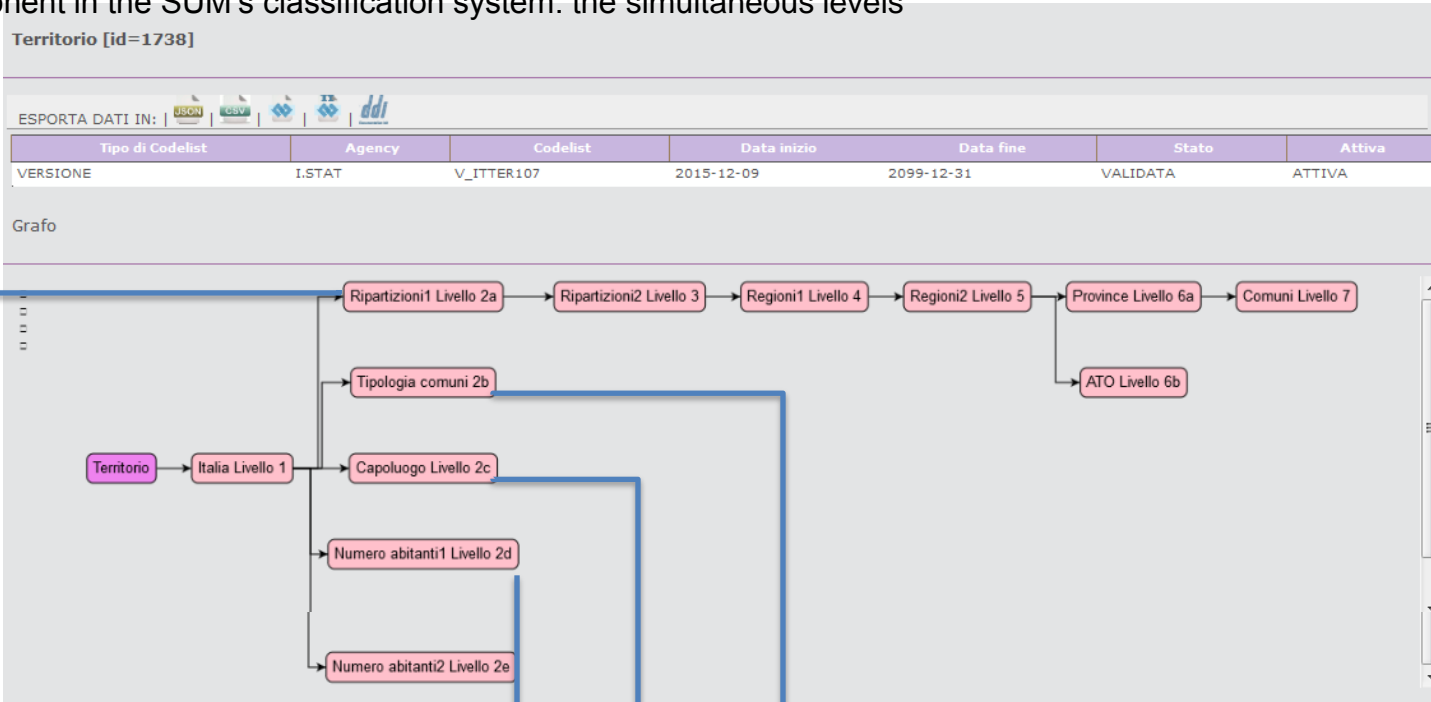
The "Classificazione Territorio" item is further expanded, showing a list of specific classification codes and their status:

- ATO 1999 [1.0]
- Bacini idrografici 1999 [1.0]
- Codici dei comuni, province e regioni 01-2012 [1.0]
- Codici dei comuni, province e regioni 03-2014 [1.0]
- Codici dei comuni, province e regioni 06-2012 []

Blue arrows indicate the navigation path from the main list to the expanded "Territorio e classificazioni geografiche" category, and then to the expanded "Classificazione Territorio" sub-category.

The Istat metadata system SUM: classification

New component in the SUM's classification system: the simultaneous levels



Elenco Modalita per la Codelist: Ripartizioni1 Livello 2a [id=1740]

Codice	Nome Ita	Nome Eng
ITCD	Nord	Nord
ITEx	Centro	Centro (I)
ITFG	Mezzogiorno	Mezzogiorno
ITZx	Extra-Regio	Extra-Regio

Elenco Modalita per la Codelist: Tipologia comuni 2b [id=1741]

Codice	Nome Ita	Nome Eng
4	grandi comuni	big municipality
5	piccoli comuni	small municipality

Elenco Modalita per la Codelist: Capoluogo Livello 2c [id=1742]

Codice	Nome Ita	Nome Eng
PROVCAPM	comune capoluogo	provincial capitals municipality
NPROVCAPM	comune non capoluogo	not provincial capitals municipality

Elenco Modalita per la Codelist: Numero abitanti1 Livello 2d [id=1743]

Codice	Nome Ita	Nome Eng
6	fino a 2.000 ab.	until 2,000 inhab.
7	2.001 - 10.000 ab.	2,001 - 10,000 inhab.
8	10.001 - 50.000 ab.	10,001 - 50,000 inhab.
9	50.001 ab. e più	50,001 inhab. and over

Data content

In SUM, we introduced the “data content” concept. It is defined according to the GSIM (specification) lines 47-50: *Each **data** is a result of a Process step through the application of a Process method on the necessary Inputs.* Hence it is modelled by specifying:

Example:

Monthly average
household expenditures

-Statistical Program and Statistical Program Cycle



Labour force survey +
Time dimension and Freq
dimension

-Process Step (phase)



Dissemination

-Process Method




Average

-Inputs



Population (Households)
+ Numeric variable
(monthly expenditures)

The Istat metadata system SUM: data content











 **SUM** SISTEMA UNITARIO METADATI

ID Operatore: casagran
Profilo: Supervisore
Version 2.5 - 25 Febbraio 2016

Home Unità statistiche Variabili statistiche e concetti Altre liste **Indicatori statistici** Logout

Elenco indicatori prodotti da rilevazioni Istat, frutto di elaborazioni o derivanti da fonti esterne all'Istituto

td8

ID indicatore	Nome indicatore	Definizione	Rilevazione, elaborazione o fonte	Dettagli
TD8_FAM_VAL_PERC_POV	famiglie (val. perc.)		Indagine sulle spese delle famiglie	
TD8_FAM_ARR_SPESA	famiglie che dichiarano di avere arretrati per alcune voci di spesa		Indagine sulle condizioni di vita (EU-SILC)	
TD8_FAM_NO_BENDUR	famiglie che dichiarano di non potersi permettere alcuni beni durevoli		Indagine sulle condizioni di vita (EU-SILC)	
TD8_FAM_NO_SOLDI	famiglie che dichiarano in alcuni periodi dell'anno di non avere soldi per voci di spesa		Indagine sulle condizioni di vita (EU-SILC)	
TD8_FAM_GIUD_CARICO	famiglie che giudicano pesante il carico delle spese		Indagine sulle condizioni di vita (EU-SILC)	
TD8_SPESA_EFF_ABB	famiglie che hanno effettuato la spesa per abbigliamento e calzature		Indagine sui consumi delle famiglie	
TD8_SPESA_EFF_FAM	famiglie che hanno effettuato la spesa per alcune voci di spesa		Indagine sui consumi delle famiglie	
TD8_SPESA_EFF_BENDUR	famiglie che hanno effettuato la spesa per beni durevoli		Indagine sui consumi delle famiglie	
TD8_SPESA_EFF_SANIT	famiglie che hanno effettuato la spesa per beni e servizi sanitari		Indagine sui consumi delle famiglie	
TD8_SPESA_EFF_PASTI	famiglie che hanno effettuato la spesa per consumazioni fuori casa		Indagine sui consumi delle famiglie	

The Istat metadata system SUM: data content

Input

Process Method

SUM SISTEMA UNITARIO METADATI

ID Operatore: casagran
Profilo: Supervisore
Version 2.5 - 25 Febbraio 2016

Home | Unità statistiche | Variabili statistiche e concetti | Altre liste | Indicatori statistici | Logout

Dati di approfondimento per il macrodato "famiglie che hanno effettuato la spesa per abbigliamento e calzature"

Popolazione	Var. Cat. Prin.	Var. num.	Unità Misura	Operatore	Fatt. Scala
Famiglie di fatto	-	spesa mensile	EURO	valori medi, media aritmetica semplice	

[← Torna alla schermata precedente](#)

Statistical program and
Statistical program cycle

Process Step

Nome rilevazione, elaborazione, fonte	Edizione	Data	Fase	Approfondimento
Indagine mensile su fatturato ed ordinativi	390	2012_M_11	Validazione	Unità funzionali
Rilevazione degli incidenti stradali con lesioni a persone	510	2014_A_0	Validazione	Incidenti
Rilevazione statistica sulla formazione nelle imprese	411	2010_A_0	Validazione	Imprese con almeno 10 addetti
Rilevazione sulle forze di lavoro	311	2015_T_2	Validazione	Individui
Rilevazione sulle forze di lavoro	311	2015_T_2	Validazione	Famiglie di fatto

Data Content feeds the GSIM concept **Measure** in a Data Structure.

Object	Group	Definition	Explanatory Text
Measure Component	Structures	The role given to a <i>Represented Variable</i> in the context of a <i>Data Structure</i> to hold the observed/derived values for a particular <i>Unit</i> in an organized collection of data.	A <i>Measure Component</i> is a sub-type of <i>Data Structure Component</i> . For example age and height of a person in a <i>Unit Data Set</i> or number of citizens and number of households in a country in a <i>Data Set</i> for multiple countries (<i>Dimensional Data Set</i>).

- ❑ SUM maintains a special code list “Data Content” where each item contains all the previous details.
- ❑ In this way a user can find the meaning of the data in a hypercube in a unique place.
- ❑ Furthermore a data producer has a form to complete for describing any new data content (*data content structure*).
- ❑ Any data producer should describe the “Data Content” according to the same “structure”.

Statistical Program						
Indicator	<u>Population</u>	<u>Variable</u>	Operator	<u>Conditioning variable</u>	<u>Unit measure</u>	<u>Scale factor</u>

- ❑ If the “Data Content” is not well defined, the meaning of data is not easy to understand and massive use of mappers should be foreseen for data and metadata exchange.

Data Structures



Dimensional Data Structures (macro)

Unit Data Structure (micro)

GSIM states that “A *Data Structure* describes the structure of a *Data Set* by means of *Data Structure Components* (*Identifier Components*, *Measure Components* and *Attribute Components*).”

Dimensional Data Structures (macro)

- Statistical program
- Reference time
- Phase

Metadata that identify a data set

- Data content
- Categorical variables
- Time dimensions
- Other dimensions
- Attributes (unit measure, unit multiplier, obs. status,..)

Metadata that specify the meaning of each datum

- Data input
- Method of transformation

Metadata on the relationship between datasets

Unit Data Structure (micro)

- Statistical program
- Reference time
- Phase
- Reference population

Metadata that identify a data set

- Unit identifier
- Numerical/quantitative variables
- Categorical variables
- Textual variables
- Macrodata requested at the microdata level
- Attributes (maximum number of answers, rules, structural zeros,...)
- Paradata


Metadata that specify the meaning of each datum

- Relationship between the investigated populations
- Data input
- Method of transformation

Metadata on the relationship between datasets

Search functionalities

Dimensional Data Structures (macro)



SISTEMA UNITARIO METADATI

ID Operatore: casagran
 Profilo: Supervisore
 Version 2.5 - 25 Febbraio 2016

Home
Ricerca strutture dati Macro
Ricerca strutture dati Micro
Questionario
Logout

Ricerca strutture dati macro

[Rimuovi tutti i filtri](#)
3744 Risultati

[per rilevazione, elaborazione, fonte](#)

9° Censimento generale dell'industria e dei servizi - Rilevazione sulle istituzioni pubbliche (3)
 Automobile club d'Italia (Aci) (2)
 Bilanci consuntivi degli enti previdenziali (1)
 Capacità degli esercizi ricettivi (4)
 Censimento delle acque per uso civile (4)
 Censimento generale della popolazione e delle abitazioni (112)
 Cessioni/acquisti beni con i paesi UE (sistema Intrastat) (6)
 Commercio speciale esportazione/importazione extra UE (6)
 Consiglio di Stato - Movimento dei procedimenti del contenzioso amministrativo (2)
 Consiglio giustizia amministrativa - Regione Sicilia (1)
 Consumi delle famiglie (9)
 Conti di tipo NAMEA (matrice di conti economici integrata con conti ambientali) (24)
 Conto economico e prestazioni della protezione sociale (136)
 Corsi di diploma universitario (4)

oneri di utilità sociale (art.. 65 tuir), sussidi occasionali e altre erogazioni in natura di carattere...
[\[vedi tutto\]](#)
 ASL (1)
 ASL con servizio di assistenza domiciliare integrata attivo (1)
 ASL con servizio di assistenza domiciliare integrata attivo (valori percentuali) (1)
 Indice del costo di costruzione di opere di imbocco - dati mensili - Base 2010=100 (1)
[\[vedi tutto\]](#)
 Indice del costo di costruzione di un tronco stradale con tratto in galleria - dati mensili - Base 2010=100...
[\[vedi tutto\]](#)
 Indice del costo di costruzione di un tronco stradale senza tratto in galleria - dati mensili - Base...
[\[vedi tutto\]](#)
 Indice del costo di costruzione di un viadotto - dati mensili - Base 2010=100 (1)
 Indice del costo di costruzione di una galleria tipo 1 (in condizioni normali) - dati mensili - Base...

ASL con servizio di assistenza domiciliare integrata (1)
 Abitazioni (7)
 Abitazioni con impianto di riscaldamento (1)
 Abitazioni occupate da persone residenti in edifici residenziali (1)
 Abitazioni occupate da residenti (1)
 Acquisizioni della cittadinanza italiana (3)
 Addetti delle imprese (1)
 Altro tipo di alloggio (2)
 Alunni con disabilità (1)
 Apprendisti (3)
 Archivi di stato e delle sezioni (4)
 Autori di delitto denunciati/arrestati dalle Forze di polizia (1)
 Aziende agricole (42)
 Aziende sanitarie locali (Asl) (2)
 Biblioteche (8)
 Cancellati dall'anagrafe (3)

Nome rilevazione, elaborazione, fonte	Nome indicatore	Nome struttura dati	DSD (Registry SDMX)
Rilevazione sulle piccole e medie imprese e sull'esercizio di arti e professioni (PMI)	primo quartile del costo del lavoro - migliaia di euro	Statistiche nazionali sulla struttura delle imprese (dati dal 2008)	
Rilevazione sulle piccole e medie imprese e sull'esercizio di arti e professioni (PMI)	terzo quartile del valore aggiunto - migliaia di euro	Statistiche nazionali sulla struttura delle imprese (dati dal 2008)	
Rilevazione sulle piccole e medie imprese e sull'esercizio di arti e professioni (PMI)	primo quartile del fatturato - migliaia di euro	Statistiche nazionali sulla struttura delle imprese (dati dal 2008)	
Rilevazione sulle piccole e medie imprese e sull'esercizio di arti e professioni (PMI)	numerosità delle imprese con fatturato>0	Statistiche nazionali sulla struttura delle imprese (dati dal 2008)	
Rilevazione sulle piccole e medie imprese e sull'esercizio di arti e professioni (PMI)	secondo quartile (mediana) della competitività di costo	Statistiche nazionali sulla struttura delle imprese (dati dal 2008)	

Unit Data Structure (micro)

The screenshot displays the SUM (SISTEMA UNITARIO METADATI) web interface. At the top, the logo 'SUM' and the text 'SISTEMA UNITARIO METADATI' are visible. The user is logged in as 'casagran' with the profile 'Supervisore' and version '2.5 - 25 Febbraio 2016'. The navigation menu includes 'Home', 'Ricerca strutture dati Macro', 'Ricerca strutture dati Micro', 'Questionario', and 'Logout'.

The main content area is titled 'Ricerca strutture dati micro'. It features three search filters:

- per rilevazione, elaborazione, fonte**: Indagine mensile su fatturato ed ordinativi (1), Rilevazione degli incidenti stradali con lesioni a persone (1), Rilevazione statistica sulla formazione nelle imprese (1), Rilevazione sulle forze di lavoro (2).
- per fase**: Validazione (5).
- per unità statistica**: Famiglie di fatto (1), Imprese con almeno 10 addetti (1), Incidenti (1), Individui (1), Unità funzionali (1).

A 'Rimuovi tutti i filtri' button shows 5 results. Below the filters, the 'Risultati della ricerca' section contains a table with the following data:

Nome rilevazione, elaborazione, fonte	Edizione	Data	Fase	Approfondimento
Indagine mensile su fatturato ed ordinativi	390	2012_M_11	Validazione	Unità funzionali
Rilevazione degli incidenti stradali con lesioni a persone	510	2014_A_0	Validazione	Incidenti
Rilevazione statistica sulla formazione nelle imprese	411	2010_A_0	Validazione	Imprese con almeno 10 addetti
Rilevazione sulle forze di lavoro	311	2015_T_2	Validazione	Famiglie di fatto

Comparisons and implementation of Gsim

GSIM concept	SUM presence
Population	Yes
Unit type	Not yet
Conceptual variable	Not yet
Represented variable	Yes
Instance variable	No
Classification	Yes (slight different definition)
Code list	Yes
Category set	Not yet
Data set	Yes (fixing roles for dimensions)
	Furthermore: Data content (for macro data structures)

Benefits and more

- ❑ The use of GSIM concepts helps in harmonizing the description of a dataset between each phases.



Output = transformation (input)

- ❑ Among the concepts already available in GSIM, an additional concept (the “**Data Content**”) could be useful in order to feed in a standard and complete way a Measure of a Data Structure (of macrodata).
- ❑ This is what we have done in Istat. The corporate DWH (I.Stat) has more than 3300 “data contents”. In SUM it is possible to search data through different facets:
 - ✓ Statistical program
 - ✓ Reference population of the data
 - ✓ Numerical variables used for the production of a data content
 - ✓ Categories of a categorical variable used in data structures

Thanks for your attention

