Calidad de Datos e Información

CaDQM

Phase 2 – DQ Assessment

ST4 – Data Quality Model Definition

- Actividades
  - *Prioritization and selection of DQ problems*
  - *Selection of DQ dimensions and DQ factors*
  - ***Definition of DQ metrics***
  - *Implementation of DQ methods*

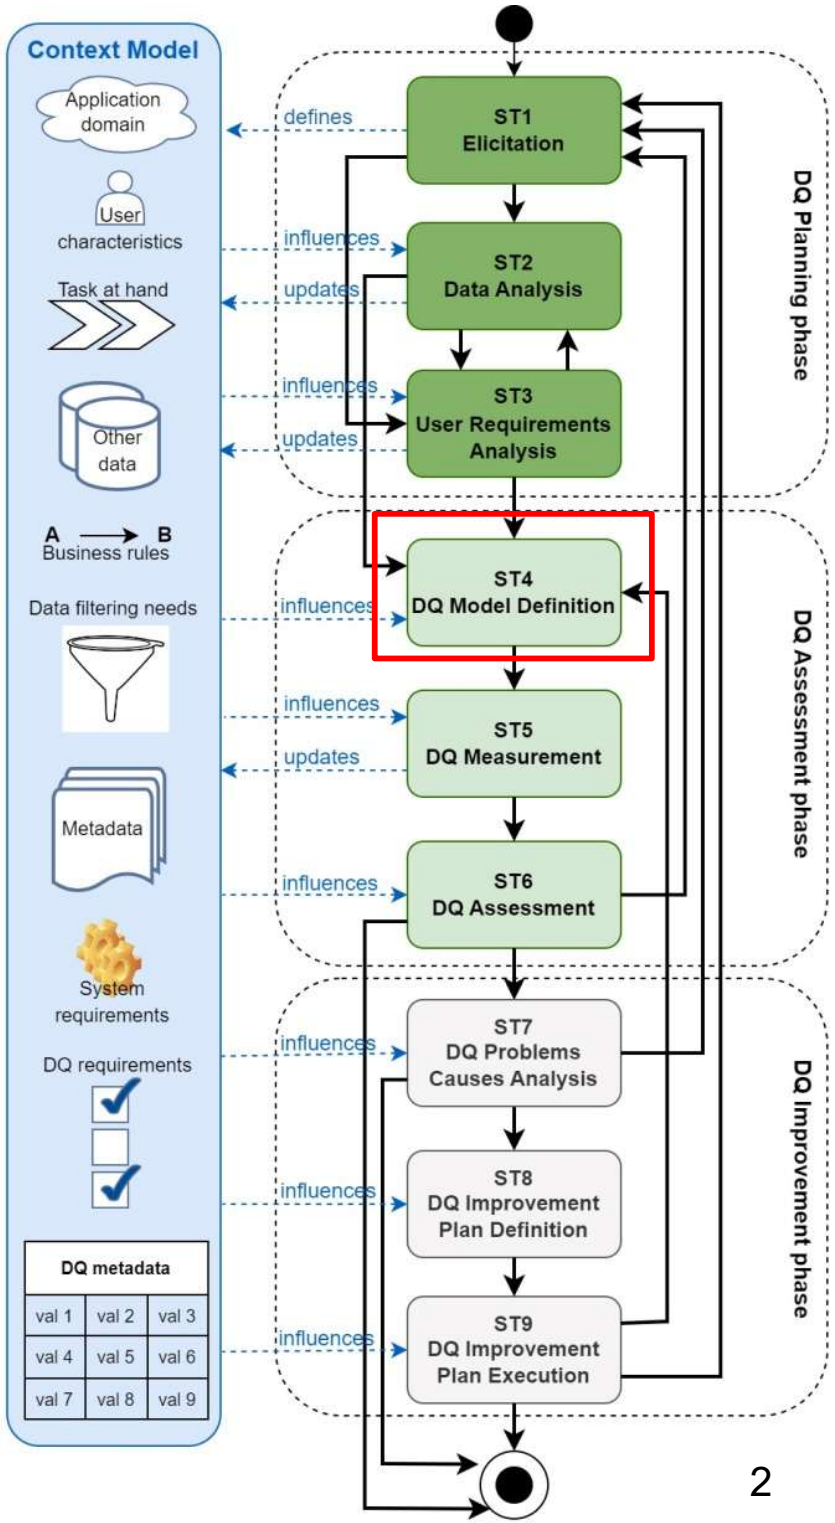

Actividades en ST4 – DQ Model definition

- *Definition of DQ metrics*

- Métrica de Calidad - Especificación
  - Un nombre
  - Una descripción (qué se mide)
    - Cantidad de valores nulos, cantidad de tuplas, tiempo transcurrido desde la última actualización
  - Las unidades de medición (dominio del resultado)
    - tiempo de respuesta en ms, volumen en GB, un valor entre 0 y 1, etc.
  - La granularidad de la medida
    - Fuertemente dependiente del modelo de datos
    - Modelo relacional: celda, tupla, columna, tabla, grupo de tablas, base de datos

- Una métrica define la forma de medir un factor de calidad

Actividades en ST4 – DQ Model definition

- *Definition of DQ metrics*

- Jerarquía de Conceptos de Calidad:
  - Dimensiones:
    - Facetas de la calidad a alto nivel.
  - Factores:
    - Aspectos particulares de las dimensiones.
  - Métricas:
    - Cada factor puede medirse con varias métricas.
  - Métodos:
    - Cada métrica puede implementarse con varios métodos.

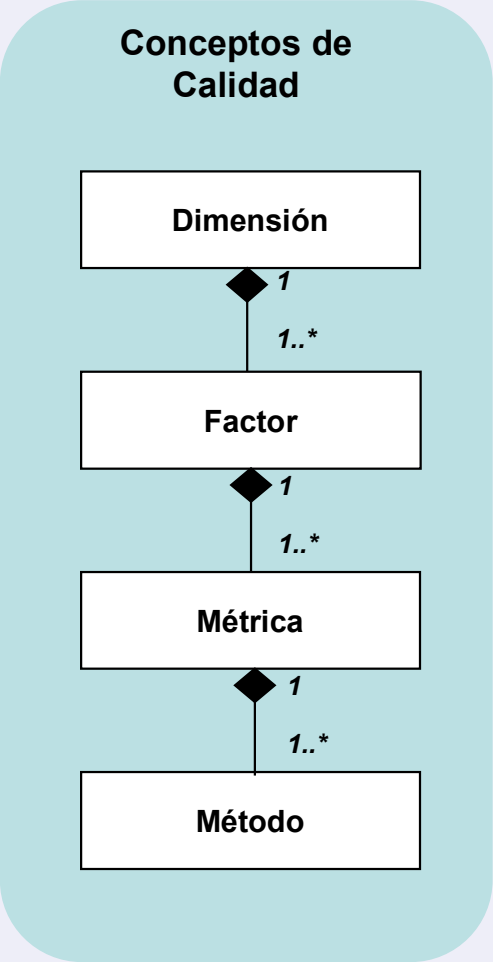

Métrica de Calidad

- Ejemplo Métrica 1:

Nombre: ExacSemantica-Bool	
Descripción:	Mide si un dato existe en la realidad.
Granularidad:	Celda
Dominio del Resultado:	{0,1}

- Ejemplo Métrica 2:

Nombre: Densidad-Grado	
Descripción:	Mide el grado de densidad de una columna.
Granularidad:	Columna
Dominio del Resultado:	[0..1]

Agregación de medidas

- Medida de calidad
  - Es el valor obtenido por la aplicación de una métrica de calidad durante una medición (Ejemplo: 0 o 1)
- Granularidad
  - En Modelo Relacional puede ser: Celda, Tupla, Atributo (columna), Tabla (o relación)
  - Análogamente en otros modelos
    - En XML/JSON podría ser: cada dato de determinados tags, o un documento.
- Agregación
  - Obtener a partir de la medida a determinado nivel de granularidad, la medida a un menor nivel de granularidad
  - Ej.: A partir de las medidas de las celdas, una medida para toda la tabla.

Agregación de medidas

- Agregamos de celda a columna
  - Ejemplo para el factor exactitud semántica

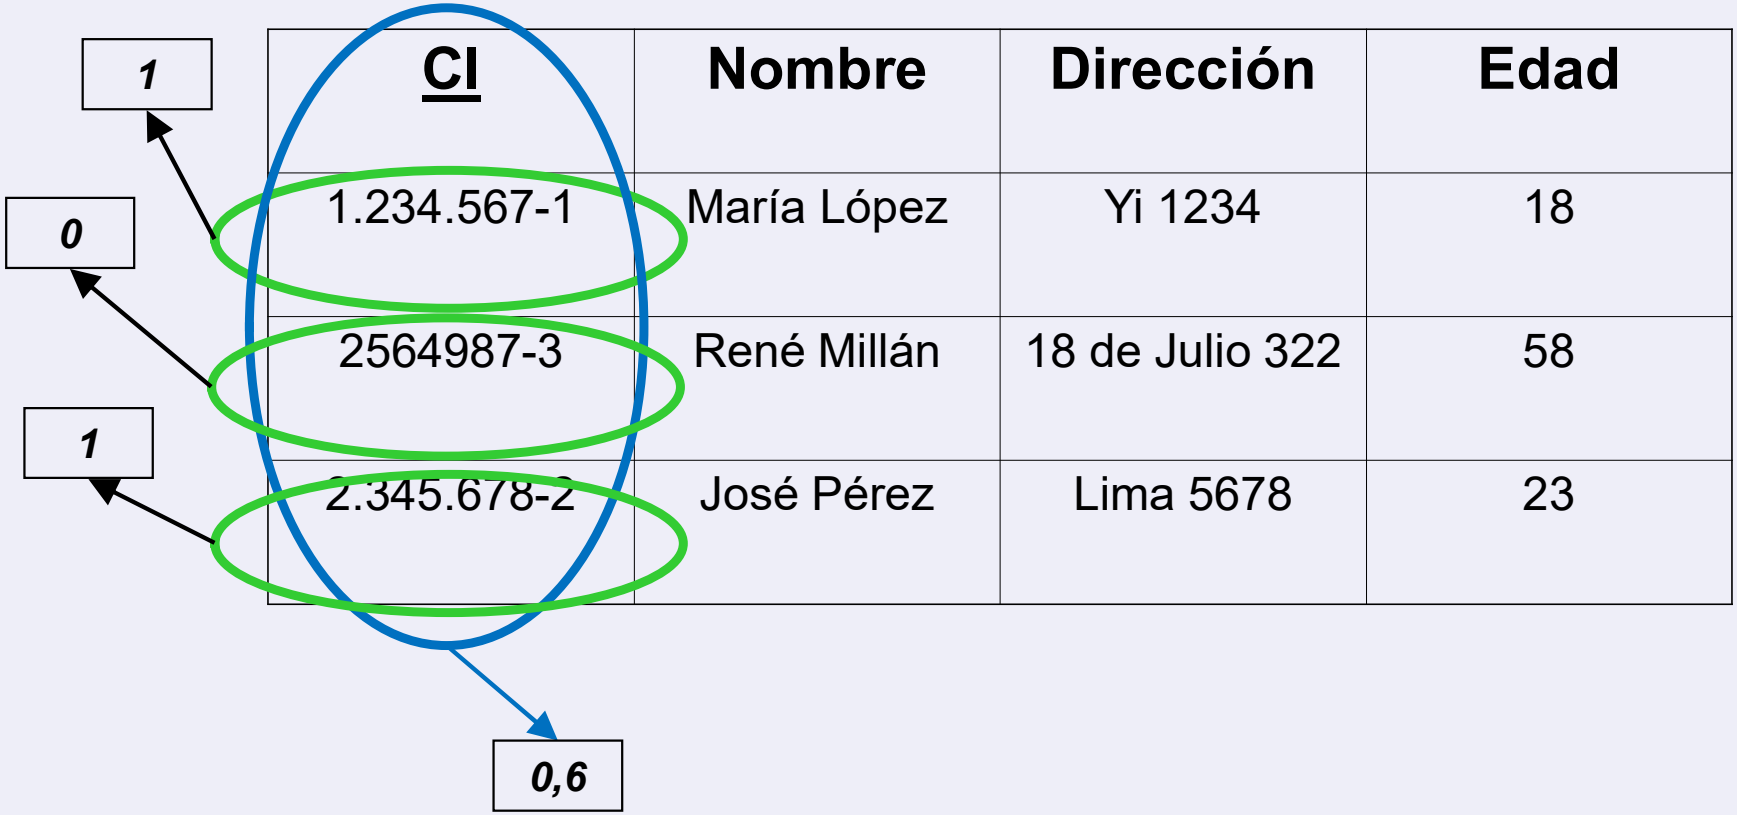

CI	Nombre	Dirección	Edad
1.234.567-1	María López	Yi 1234	18
2564987-3	René Millán	18 de Julio 322	58
2.345.678-2	José Pérez	Lima 5678	23

Métricas comunes para las dimensiones

- Exactitud
- Completitud
- Frescura
- Consistencia
- Unicidad

Métricas comunes para las dimensiones

- Exactitud
- Completitud
- Frescura
- Consistencia
- Unicidad

Exactitud (Accuracy)

- Factores
  - Exactitud semántica (semantic accuracy)
  - Exactitud sintáctica (syntactic accuracy)
  - Precisión (precision)

Métricas de exactitud

- Tres familias de métricas:
  - Booleanos:
    - Indican si un dato es correcto o no. Valores {0, 1}
    - Ejemplo: un teléfono es válido o no; no hay matices.
  - Funciones de comparación de valores:
    - Miden la cercanía entre un valor v del SI y un valor v' correcto.
      - Ejemplo: *edit distance*
    - Se pueden normalizar. Ej.: distancia (18153, 18532) / 18532
  - Grados:
    - Miden el grado de confianza en la exactitud del dato.
    - En gral. se asignan valores entre 0 y 1.
    - Pueden provenir de procesos automáticos de medición o reconocimiento.
    - Ejemplo: son reconocidos como 'C' con exactitudes

0.80, 1.00 y 0.65 respectivamente

Métricas y mediciones de exactitud

- La **exactitud semántica** involucra una comparación del SI con el mundo real. Suele ser muy costoso.
  - Ejemplos:
    - Contratar personal que llame por teléfono a todos los clientes y verifique datos.
    - Enviar cartas/emails con promociones que incentiven a los clientes a enviar sus datos.
    - Crear leyes/procedimientos que obliguen a las empresas a declararse
    - Crear procedimientos que obliguen a los estudiantes a registrarse a un curso dejando info de contacto.

- Alternativa:
  - Comparar contra un referencial considerado como válido u otra BD.
  - Ejemplos:
    - Verificar RUTs de empresas contra listado de la DGI
    - Verificar teléfonos de los clientes contra una guía telefónica
    - Verificar datos de empleados contra la BD contable de la empresa

Métricas y mediciones de exactitud

- Para el factor Exactitud semántica

Resumen:

- **Booleano de exactitud semántica**

  Si un dato es exacto o no.

- **Desviación de exactitud semántica**

  Distancia a los datos exactos.

- **Grado de exactitud semántica**

  Impresión de la exactitud semántica de los datos.

Métricas y medición de exactitud

- La **exactitud sintáctica** implica verificar si un dato está bien escrito.

- Dos formas de verificar:

  - **Por extensión:** Comparar con un **diccionario** que representa el dominio.
    - Ej: los nombres de las calles deben estar en la guía de calles
    - Algunos dominios son difíciles de representar. Ej.: apellidos válidos

  - **Por comprensión:** Chequear si satisfacen **reglas de sintaxis**.
    - Ejemplos de reglas:
      - Los teléfonos internos tienen 4 dígitos
      - Las CI deben de verificar el dígito de control
      - Las direcciones tienen la forma calle número apto CP ciudad

    - Las reglas aseguran que los datos se almacenan en un mismo formato y son compatibles con datos anteriores

Métricas de exactitud

- Para el factor Exactitud sintáctica

Resumen:

- **Booleano de exactitud sintáctica**:

  Si un dato es sintácticamente correcto o no.

- **Desviación de exactitud sintáctica** :

  Distancia a los datos correctos más parecidos.

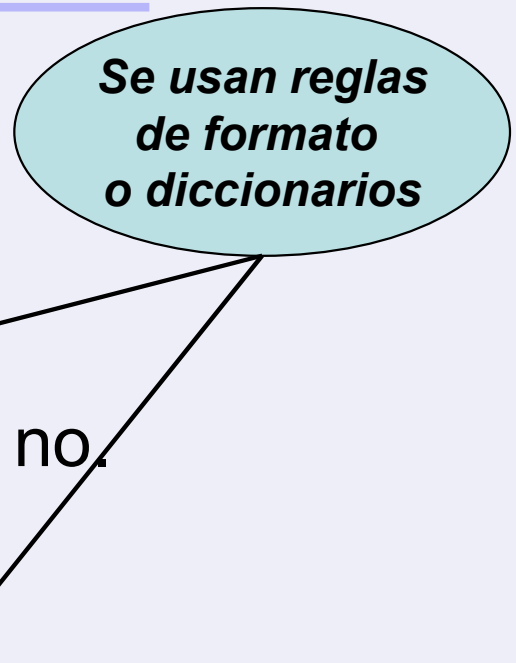

Ejemplo

- Desviación de exactitud sintáctica
  - Función de comparación: Edit distance (Levenshtein distance)
    - Evalúa la distancia del valor almacenado al valor válido más cercano (del dominio correspondiente).
    - Es la mínima cantidad de operaciones (inserciones, borrados y reemplazos de caracteres), necesarios para pasar de un string a otro.

Métricas y medición de exactitud

Referenciales:

- Verifican **correctitud semántica.**
- Contienen un conjunto de parejas <clave, valor>
  - Clave representa una entidad o estado del mundo real
  - Valor representa un atributo de dicha entidad
  - Ej. <CI, nombre>
- Dos tipos de chequeos:
  - Verificar que la clave pertenezca al referencial (se detectan mismembers).
  - Verificar que la clave esté asociada al valor correcto.

Diccionarios:

- Verifican **correctitud sintáctica.**
- Contienen una lista de valores válidos para un dominio.
  - Ej. Nombres de calles
- El chequeo consiste en verificar que un dato pertenezca al diccionario.

Métricas de exactitud

- Para el factor **Precisión**:
  - **Escala**: Escala de la medición
    - Ej. 87 ± 1 cm
    - Ej. “Rojo” vs. “204R-51G-0B”
    - Ej. “Interior” vs. “Colonia”
  - **Error estándard**: Desviación estándar de un conjunto de mediciones.
    - Ej. medidas de tráfico tomadas por varios sensores
  - **Granularidad**: Cantidad y cobertura de los atributos que representan un concepto.
    - Ej. calle, número de puerta, ciudad, código postal y país para representar una dirección.

Precisión del agente o instrumento de medición

Jerarquía de precisiones de valores del dominio

Varios valores para un mismo estado/entidad

Esquema de datos

Descomposición de texto libre

Ejercicio 6

- Considerando los ejercicios realizados anteriormente en clase (Ej. 1 al 5), para algunos de los factores de Exactitud identificados:

  Dar una **métrica de calidad** de **Exactitud.**

Agregaciones para exactitud

- Para medir la exactitud de conjuntos de datos (ej. tablas), en función de la exactitud de cada dato se usan:
  - **Ratios:**
    - AccuracyRatio(S) = $\mathbf{|\{a_i / a_i = 1\}| / n}$ (booleanos)
    - AccuracyRatio(S) = $\mathbf{|\{a_i / a_i \geq \theta\}| / n}$, $0 \leq \theta \leq 1$ (distancias y grados)
  - **Promedios:**
    - AccuracyAvg(S) = $\mathbf{(\Sigma_i\ a_i) / n}$
  - **Promedios ponderados:**
    - Accuracyweight(S) = $\mathbf{\Sigma_i\ w_i\ a_i}$, $0 \leq w_i \leq 1$, $\Sigma_i\ w_i = 1$

Nota: 1 es un valor correcto, 0 es un valor incorrecto

Agregaciones para exactitud

- Otras agregaciones posibles
  - T: tabla que queremos medir, con K atributos y N tuplas.
  - T': una tabla de referencia, donde tenemos el atributo que identifica las tuplas de T, con todos los valores correctos (por ej., ci)
  - q_{ij}=0 si la celda ij es correcta, q_{ij}=1 si la celda ij es incorrecta (con i:1..N, j:1..K)
  - $q_i = \Sigma_j q_{ij}$, da la correctitud de la tupla t_i.
  - s_i=0 si la tupla t_i se corresponde con una tupla en T', si no: s_i=1.

weak accuracy error (wae): $\Sigma_i (\beta((q_i > 0) \wedge (s_i = 0)) / N)$

strong accuracy error (sae): $\Sigma_i (\beta(s_i = 1) / N)$

accuracy (acc): $\Sigma_i (\beta((q_i = 0) \wedge (s_i = 0)) / N)$

β=1 si la condición es verdadera, β=0 si es falsa

Ejercicio 7

- Dadas las agregaciones de la diapositiva anterior, para c/u:
  - Describa la semántica de cada agregación
  - Analice de qué granularidad se parte y a qué otra granularidad pasa cada agregación

Métricas comunes para las dimensiones

- Exactitud
- Completitud
- Frescura
- Consistencia
- Unicidad

Completitud (Completeness)

- Factores
  - Cobertura (coverage)
  - Densidad (density)

Métricas y medición completitud

- Al igual que la exactitud semántica, la **cobertura** involucra una comparación del SI con el mundo real.
  - Se necesitaría un **referencial**. Pero rara vez es posible obtenerlo.
  - Ejemplos:
    - Identificar todos los clientes potenciales.
    - Conocer todas las personas que están trabajando (legales o ilegales).
    - Tener la lista de todos los habitantes de una ciudad.

- Alternativa: estimar el tamaño que tendría tal referencial.
  - Ejemplos:
    - Clientes potenciales: encuestas de sondeo.
    - Trabajadores: sondeos y estimaciones.
    - Habitantes: datos del último censo.

Métricas y medición completitud

- Estimación del referencial: considerar que la realidad es la unión de los sistemas de información conocidos
  - Ejemplos:
    - Todos los vuelos a Paris son los propuestos por las agencias de viajes de Montevideo.

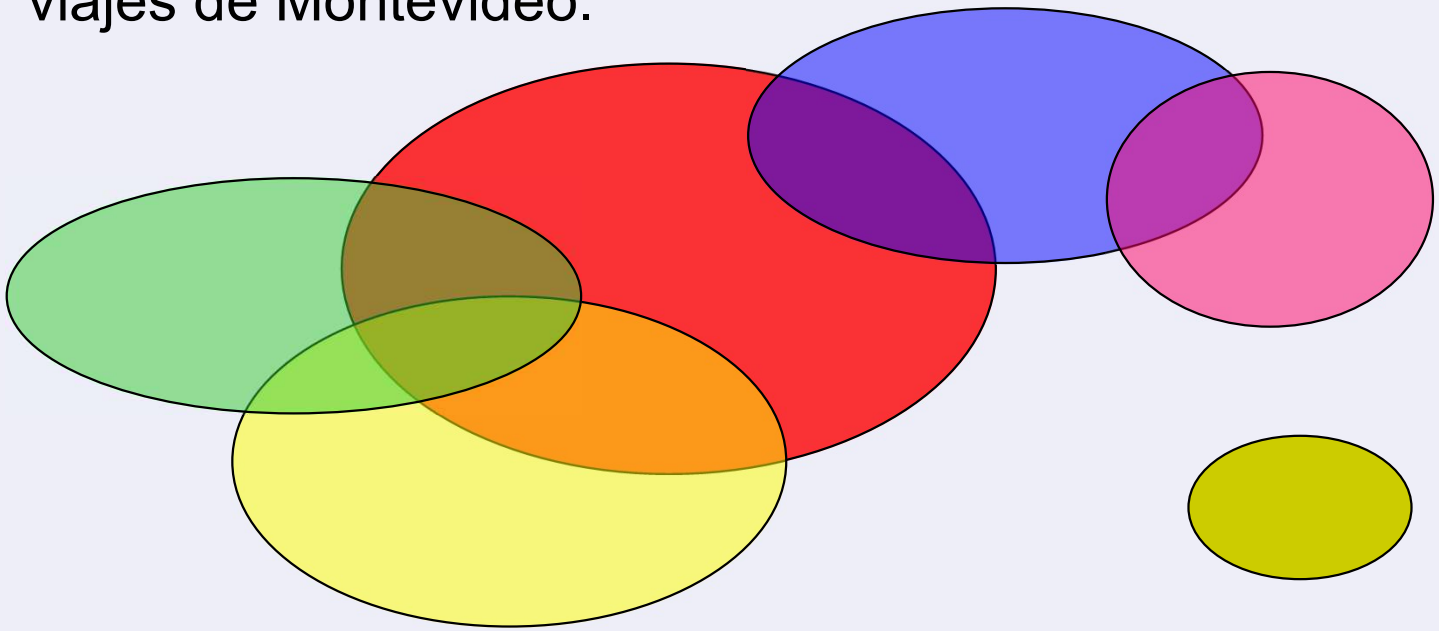

Métricas de completitud

- Para el factor Cobertura:
  - **Ratio de cobertura**:

  Porcentaje de datos contenidos en el SI

Estimación del Referencial o su tamaño

- Para el factor Densidad:
  - **Ratio de densidad**:

  Porcentaje de valores no nulos

Ponderaciones

Variantes:

- Ponderando según la importancia de los atributos.
- Ponderando grupos de atributos.
  - Ej. Si no tengo la dirección pero tengo el teléfono no es tan grave

Ejercicio 8

- Especificar la métrica de calidad para el factor cobertura, presentado en la diapositiva anterior.

- Agregar a la métrica una agregación que le parezca interesante.

Métricas comunes para las dimensiones

- Exactitud
- Completitud
- Frescura
- Consistencia
- Unicidad

Frescura (Freshness)

- Factores
  - Actualidad (currency)
  - Oportunidad (timeliness)
  - Volatilidad (volatility)

Métricas de frescura

- Para el factor Actualidad:
  - **Actualidad1**: Diferencia de tiempo entre el momento de la consulta y la primera modificación no repercutida en el SI.
  - **Actualidad2**: Relación entre: Diferencia de tiempo entre: el momento de la consulta y la última actualización y Frecuencia de cambio en la realidad (o en el origen).
  - **Booleano de frescura**: El dato está actualizado o no.

¿Cuándo ocurrieron los cambios?

Logs de los cambios

Comparación con el estado actual

- Para el factor Oportunidad:
  - **Oportunidad**: Si es actual y llegó a tiempo para la tarea.

Momento de tarea involucrada

- Para el factor Volatilidad:
  - Volatilidad: Frecuencia de cambios.

Ejercicio 9

- ¿Cómo normalizaría (a un valor entre 0 y 1) las medidas de Actualidad1 y Actualidad2?

- Tomando una tabla de Clientes cualquiera, especificar una métrica de calidad para el factor Actualidad.

Métrica Oportunidad

- Oportunidad (timeliness)

$$\text{Max}\left(0,\ 1 - \frac{t2 - t1}{t3 - t1}\right)$$

t1: instante en que el usuario solicitó el dato
t2: instante en que se entregó el dato al usuario
t3: instante en que el dato deja de ser útil

Métricas comunes para las dimensiones

- Exactitud
- Completitud
- Frescura
- Consistencia
- Unicidad

Consistencia (Consistency)

- Factores
  - Integridad de dominio (domain integrity)
  - Integridad intra-relación (relation integrity)
  - Integridad inter-relación (inter-relation integrity)

Métricas de consistencia

- Booleano de Consistencia:
  - Si el dato satisface o no las reglas (de dominio, intra-relación o inter-relación, según el factor).
  - La granularidad podría ser “celda” o “conjunto de celdas”.

- Ejemplos:

  Si 0 < edad < 120
  consistencia = 1
  sino consistencia = 0

  Si años-trabajados < 3 $\wedge$ salario-anual > 25000
  consistencia = 0
  sino consistencia = 1

Métricas de consistencia

- Agregación:
  - **Ratio de integridad**: Porcentaje de datos que satisfacen las reglas (de dominio, intra-relación o inter-relación, según el factor).
  - **Combinación:** Como puede haber varias reglas para una misma relación (o grupo de relaciones), en general se construye una suma ponderada de los resultados de medir dichas reglas.

Ejercicio 10

- Considerando una tabla cualquiera, especificar:
  - Dos **métricas de calidad** para el factor **Integridad intra-relación**.
  - Una **combinación** de esas métricas de calidad
  - Una **agregación** que le resulte interesante

Métricas comunes para las dimensiones

- Exactitud
- Completitud
- Frescura
- Consistencia
- Unicidad

Unicidad (Uniqueness)

- Factores
  - No-duplicación (duplication-free)
  - No-contradicción (contradiction-free)

Métricas de unicidad

- Booleano de Unicidad
  - Si el dato está duplicado o no, para factor No-duplicación
  - Si el dato tiene contradicción o no, para factor No-contradicción
  - La granularidad podría ser “celda” o “conjunto de celdas”.

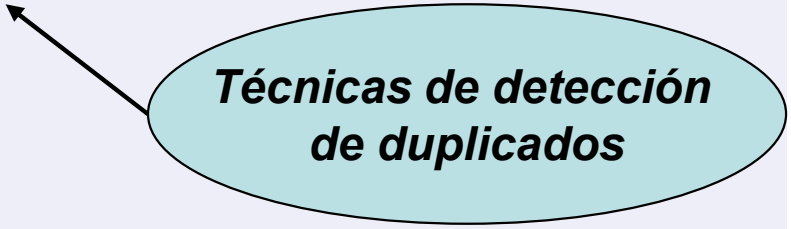

- Agregaciones
  - Para el factor No-duplicación:
    - **Ratio de no-duplicados**:

    Porcentaje de datos que no están duplicados en forma exacta.

  - Para el factor No-contradicción:
    - **Ratio de no-contradicciones**:

    Porcentaje de datos que no están duplicados con contradicciones.

Ejercicio 11

- Para los datos de una tabla cualquiera, ¿cómo mediría el factor No-Contradicción?

- ¿Qué granularidad tendría la métrica?

Bibliografía

- ***Data and Information Quality. Carlo Batini, Monica Scannapieco. Springer. ISBN: 978-3-319-24104-3. 2016.***
- ***Data Quality for the Information Age. Thomas C. Redman. 1996 Artech House Inc., ISBN 0-89006-883-6***
- ***Information Quality: Fundamentals, Techniques and Use. Felix Naumann, Kai-Uwe Sattler. EDBT Tutorial, Munich, 2006.***
- ***Data Quality. The Accuracy Dimension. Jack E. Olson. Morgan Kaufmann Publishers, Elsevier. 2003. ISBN-10 1-55860-891-5***
- ***Data Warehouse Institute Survey on Data Quality. W. Eckerson. Proceedings of the Seventh International Conference on Information Quality (ICIQ-02).***
- ***The TIQM® Quality System for Total Information Quality Management: Business Excellence through Information Excellence. Larry English. MIT Information Quality Industry Symposium, 2009.***
- ***Y. W. Lee, D. M. Strong, B. K. Kahn, and R. Y. Wang, "AIMQ: a methodology for information quality assessment," Information & management, vol. 40, no. 2, pp. 133–146, 2002.***

Bibliografía

- ***S. E. Madnick, R. Y. Wang, Y. W. Lee, and H. Zhu, "Overview and Framework for Data and Information Quality Research," J. Data and Information Quality, vol. 1, no. 1, pp. 2:1–2:22, Jun. 2009.***
- ***D. M. Strong, Y. W. Lee, and R. Y. Wang, "Data quality in context," Commun. ACM, vol. 40, no. 5, pp. 103–110, May 1997.***
- ***R. Y. Wang and D. M. Strong, "Beyond accuracy: What data quality means to data consumers," Journal of management information systems, pp. 5–33, 1996.***
- ***M. Scannapieco and T. Catarci, "Data quality under a computer science perspective," Archivi & Computer, vol. 2, pp. 1–15, 2002.***
- ***B. Otto, K. M. Huner, and H. Osterle, "Identification of Business Oriented Data Quality Metrics," presented at the ICIQ, 2009, pp. 122–134.***
- ***Y. Lee, S. Madnick, R. Wang, F. Wang, H. Zhang. A Cubic Framework for the Chief Data Officer: Succeeding in a World of Big Data. MIS Quarterly Executive, 2014.***