

CALIDAD DE DATOS

Diego Rosselli

Objetivos

- Introducción Calidad Datos

1

- Estrategia aseguramiento calidad

2

- Lecciones aprendidas

3

Objetivos

- **Introducción Calidad Datos**

1

- **Estrategia aseguramiento calidad**

2

- **Lecciones aprendidas**

3

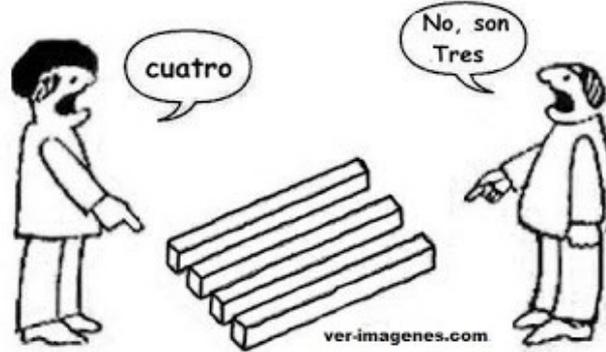
Introducción

¿ Son 3 o son 4 ?

1

Calidad:

- La percibimos
- La definimos
- La medimos



Calidad datos: ¿algo nuevo?

Reporte

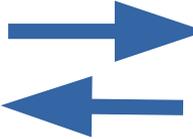
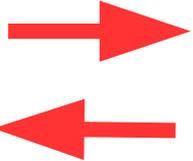
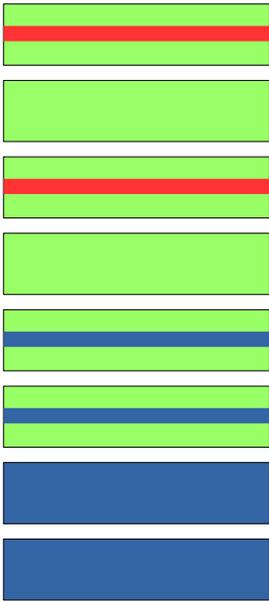
A	B	C
1	1	2
2	1	1



D	E
1	1
4	2

F	G	H
a	c	d

Datos



Gestión de calidad datos



Adecuación al uso

- Calle, número puerta
- Calle, esquina, destinatario
- Plano



Calidad - Valor - Expectativas

Puede ser correcto, preciso, actualizado y no colaborar con las necesidades del usuario.

Calidad <> Precisión



Puede no alcanzar o por el contrario superar las expectativas del usuario.

Causas de problemas de calidad

1

- Producción: ingreso manual, sensores, unificar diferentes fuentes



Causas de problemas de calidad

1

- Almacenamiento: ausencia de formato común, diseño inadecuado de base de datos



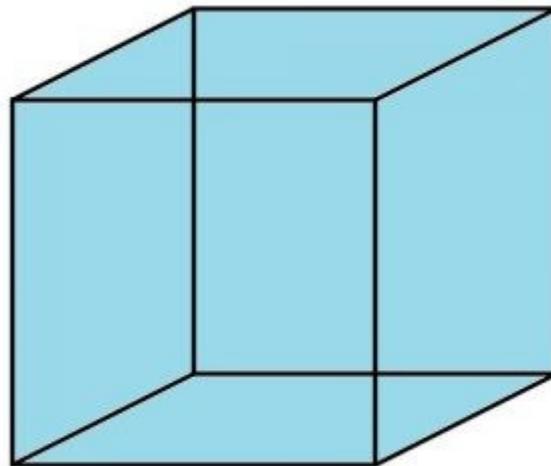
Causas de problemas de calidad

- Utilización: actualización, cambios de requerimientos, errores de interpretación



Multi-dimensión de la calidad de datos

- Completitud
- Unicidad
- Exactitud
- Consistencia
- Actualidad
- Otras: ISO/IEC 25012,
ISO 8000



Dimensión Unicidad

1

CI	Nombre	Calle	Nro.	F.Nto.	Edad
1	José	Calle A	1	A	30
11	José	Calle A	1	A	30
1	José	Calle A	1	A	30
3	María	Calle B	2	B	28
4	Juana	Calle C	3	C	29

Unicidad: Medición y Registro

1

CI	Nombre	Calle	Calidad de cada línea			
1	José	Calle A	1	A	30	0
11	José	Calle A	1	A	30	0
1	José	Calle A	1	A	30	0
3	María	Calle B	2	B	28	1
4	Juana	Calle C	3	C	29	1

Unicidad: Medición y Registro

1

CI	Nombre	Calle	Calidad de cada línea			
1	José	Calle A	1	A	30	3
11	José	Calle A	1	A	30	3
1	José	Calle A	1	A	30	3
3	María	Calle B	2	B	28	1
4	Juana	Calle C	3	C	29	1

Dimensión Completitud

Falta

Inferir

1

CI	Nombre	Calle	Nro.	F.Nto.	Edad
1	José	Calle A	1	A	30
2	Pepe			C	
4	Juana	Calle B	2		20
3	María	Calle C		D	40

NC

Estimar

Completitud: Medición y Registro

CI	Nombre	Calle	Nro.	F.Nto.	Edad
1	José	Calle A	1	A	30
2	Pepe			C	
4	Juana	Calle B	2		20
3	María	Calle C		D	40

0

1

Calidad de cada celda

Dimensión Completitud

Falta

Inferir

1

CI	Nombre	Calle	Nro.	F.Nto.	Edad
1	José	Calle A	1	A	30
2	Pepe			C	
4	Juana	Calle B	2		20
3	María	Calle C		D	40

NC

Estimar

Dimensión Correctitud sintáctica

CI	Nombre	Calle	Nro.	F.Nto.	Edad
1	José	Calle A	1	A	30
2	Pepe	Calle D	A#	C	30
4	Juana	Calle B	B&	B	40
3	María	Calle C	3	D	40

Entero > 0

Especificación de una métrica

Nombre

M1C.SintácticaNumPuerta

Valores correctos

Entero > 0

Tipo resultado

{0,1}

Granularidad

Celda

Método medición

VC

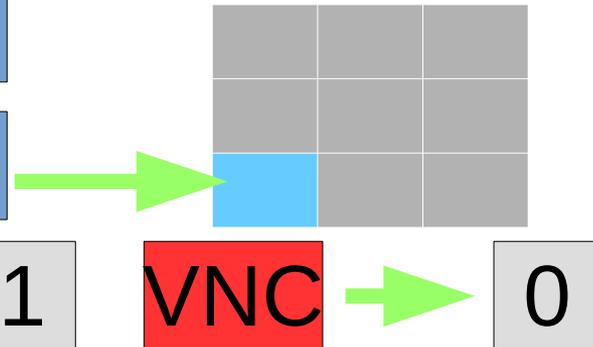


1

VNC



0



Especificación de una métrica

Nombre

M1C.SintácticaNomEmp

Valores correctos

(A-Z)(a-z)+

Tipo resultado

{0,1}

Granularidad

Celda

Método medición

VC

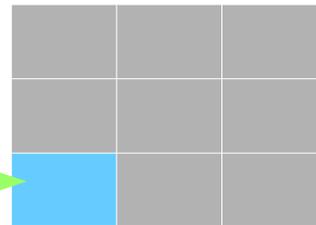


1

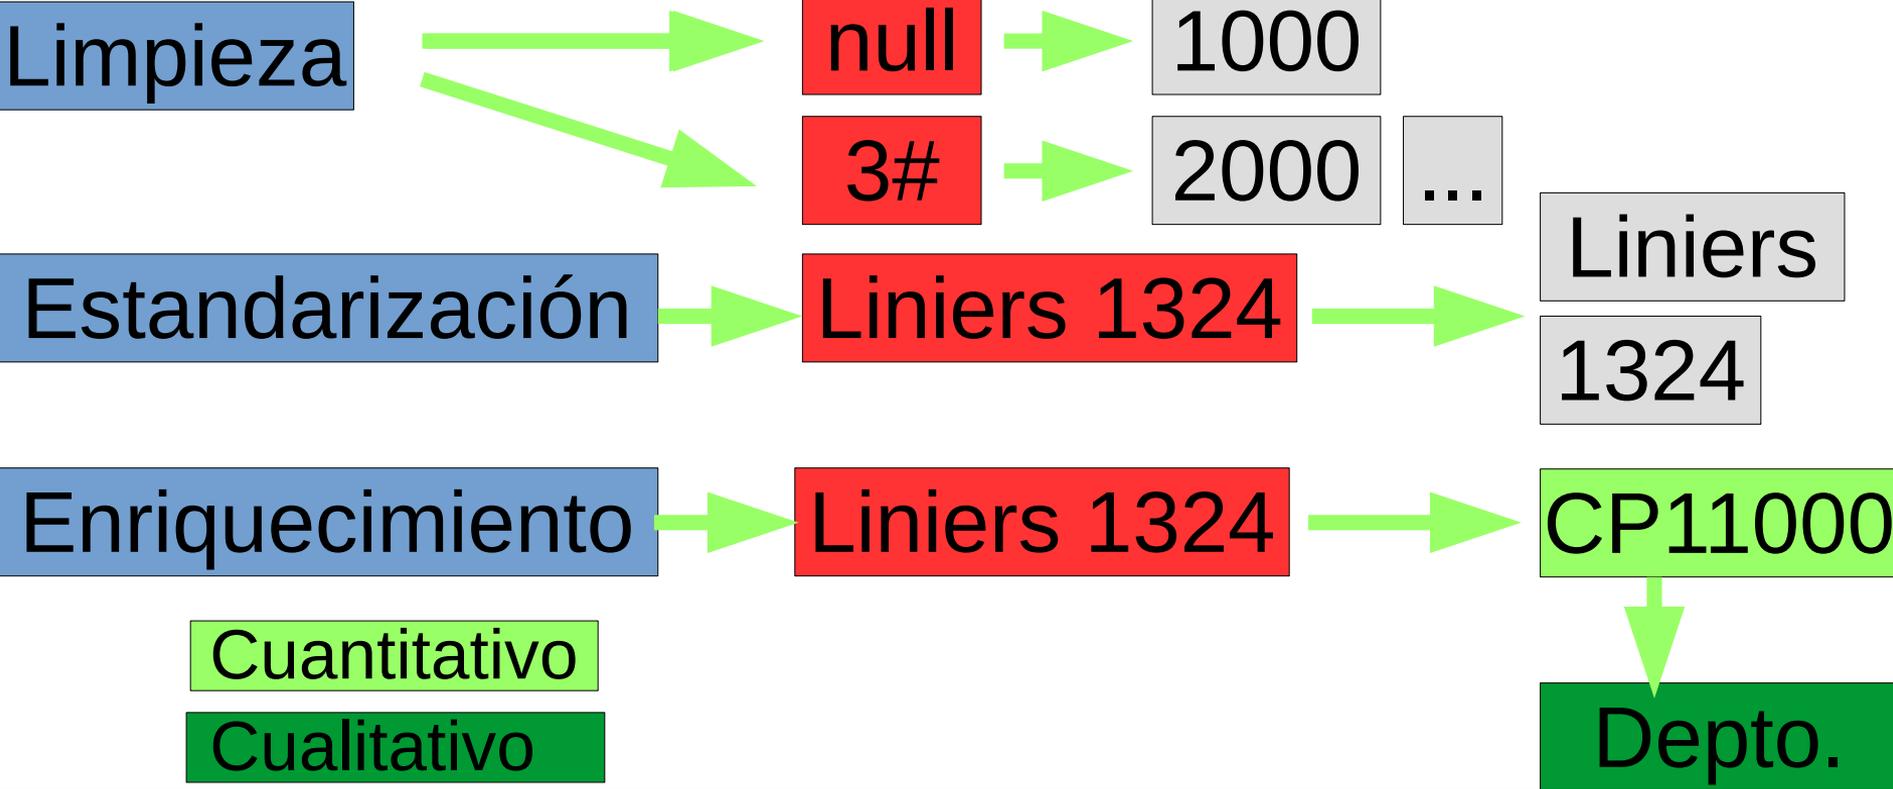
VNC



0



Corrección de errores y mejoras



Prevención de errores: Catálogos

Datos personales

CI

Nombre

Apellido

Direcciones

Liniers 1122

Liniers

1324

Esquina

Barrio

CP11000

Prevención de errores: Estándares

País

Departamento

Municipio

Localidad

Liniers 1324

Tipo vialidad

Barrio

Bloque

Nombre vialidad

...

...

Sección

Torre

Número puerta

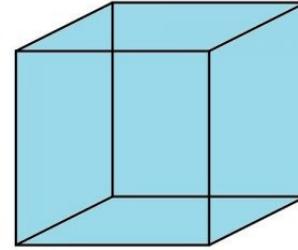
Componentes de una Dirección uy

Letra puerta

Nombre inmueble

Resumen

- Principales conceptos, y dimensiones
- Especificación métrica
- Corrección de errores
- Prevención de errores



Objetivos

- Introducción Calidad Datos

1

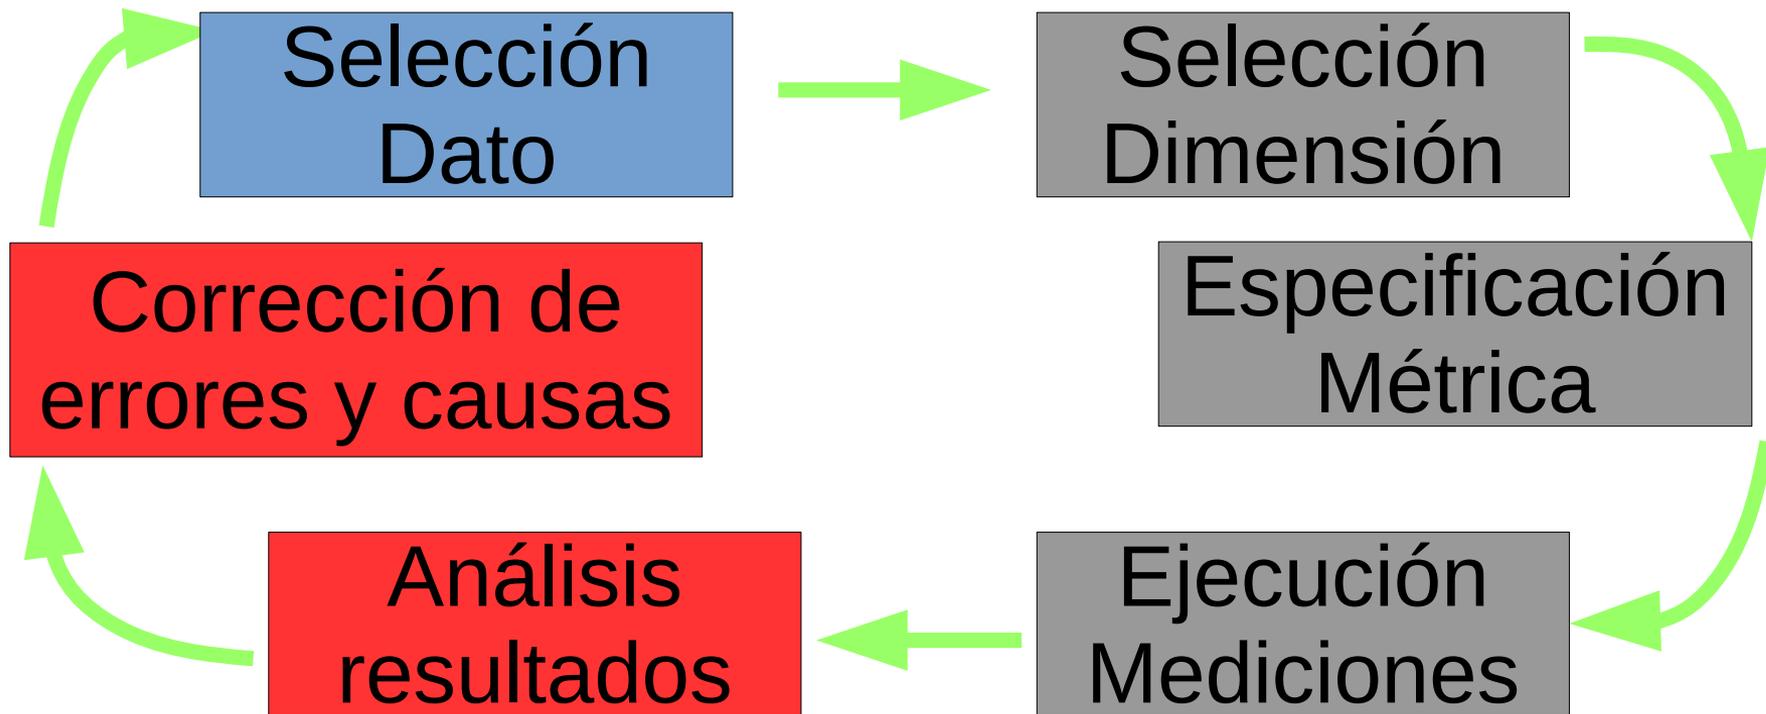
- **Estrategia aseguramiento calidad**

2

- Lecciones aprendidas

3

Mediciones de calidad



Aseguramiento de calidad

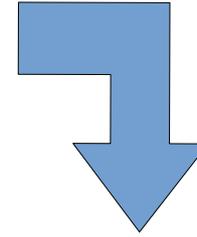
2



Dimensiones

Métricas

Mediciones



Clasificación datos

Relevancia

Prioridad

Fuente

...

...

...

Atr.	Rel.
A.1	Si
A.2	No

Atr.	Prioridad
A.3	1
A.4	3
A.6	2

Atr.	Fuente
A.5	S1
A.7	S2

Análisis calidad

Ciclo de vida del dato

Producción



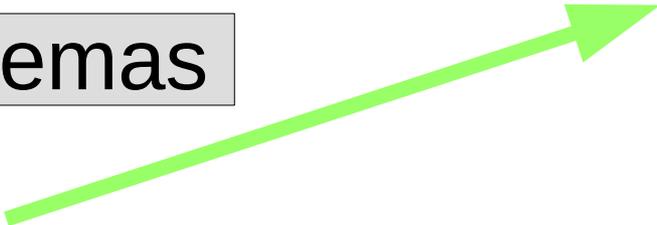
Digitación

Sensor

Otros sistemas

Juan Pepe 1a

12 11 100 1b



Uso



Edición

Actualización

Destrucción



Incorrecta

Por error



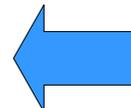
Inconsistencia

Procesos

Propios
de los datos



Negocio
Origen
Actualización
Integración

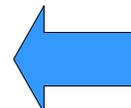


Analizar

Análisis
de calidad



Medición
Corrección

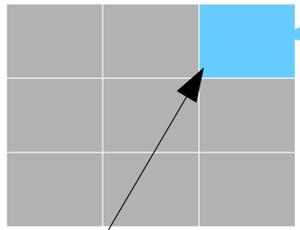


Construir

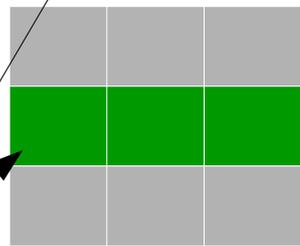
Almacenamiento resultados

- Mediciones →  BD Resultados

dimension
123 iddimension
ABC nomdimension
ABC descdimension



metrica
123 idmetrica
ABC nommetrica
ABC descmetrica
123 idgranularidad
123 idfactor



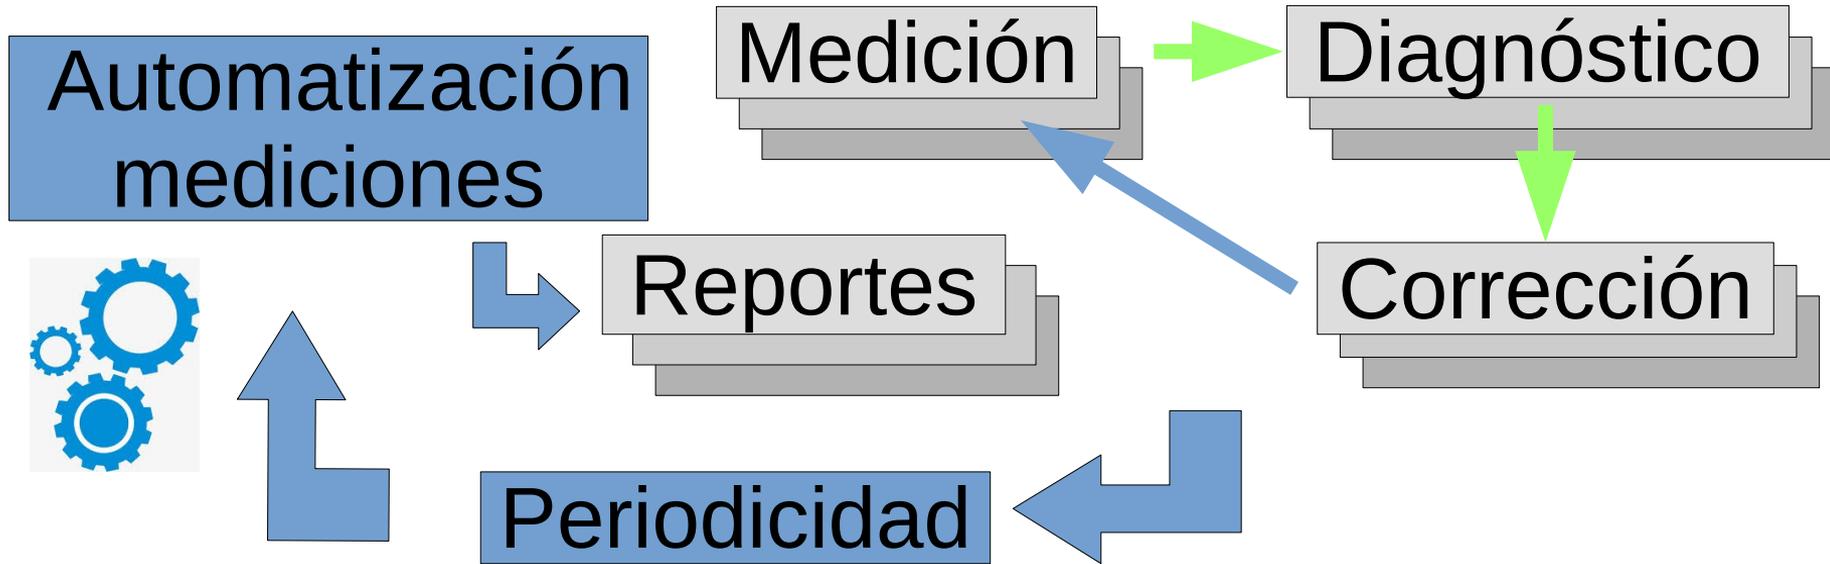
medicion
123 idmedicion
fecha
123 valor
123 idmetrica

ref_celda
123 idmedicion
123 idtabla
ABC nomatributopk
ABC valororigenpk
ABC nomatributocelda

ref_tupla
123 idmedicion
123 idtabla
ABC nomatributopk
ABC valororigenpk

Mediciones periódicas

2



Aseguramiento calidad

2

Clasificación
de datos

Mediciones
de calidad

Sistema de
gestión CD

Ciclo vida del
dato

Automatización
mediciones

Procesos

Personas-
Roles

Prevención

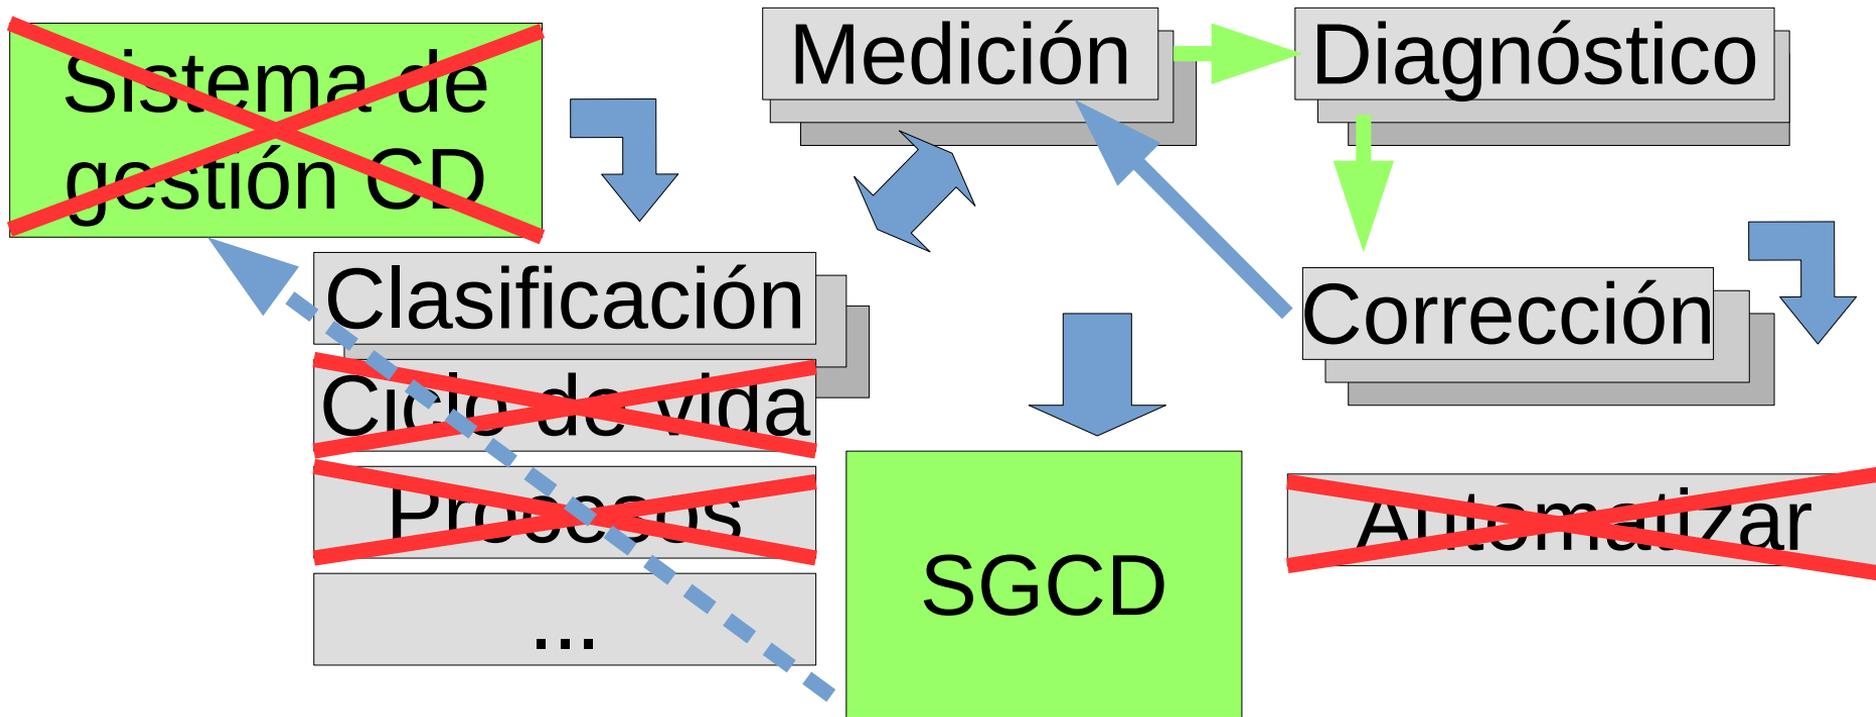
Almacenamiento
resultados



© Can Stock Photo



Estrategia de comienzo



Objetivos

- Introducción Calidad Datos

1

- Estrategia aseguramiento calidad

2

- Lecciones aprendidas

3

Herramientas

- Mediciones con Pentaho PDI
 - Simplifica implementación
 - Permite automatizar ejecución
 - Libre uso



Correcciones

- Esfuerzo importante de análisis y corrección de datos y errores



alterar
sistemas
y procesos



alterar BD

Datos generados en mediciones

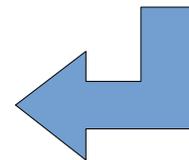
CI	Att1	Att2
1	A	10
2	B	20
1	C	30
3	D	40

celda

12 mediciones

línea

4 mediciones



Datos generados en mediciones

CI	Att1	Att2
1	A	10
2	B	20
1	C	30
3	D	40

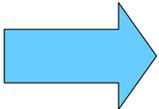
58

80.000.000

2.800.000

3

7.000.000

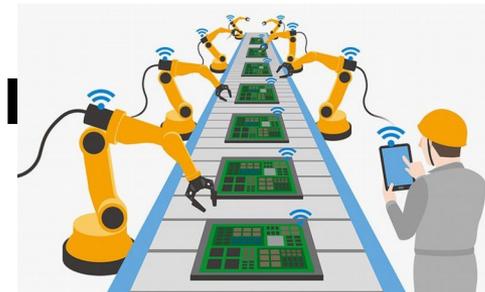


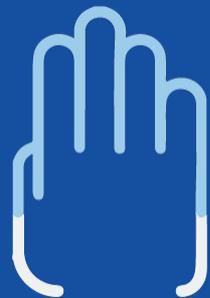
Clasificación

Granularidad

Automatización y Paneles

- Automatización de mediciones para sucesivas ejecuciones
- Diseñar panel de resultados para mostrar resultados a usuarios





Espacio de intercambio



MUCHAS GRACIAS

POR DUDAS, CONSULTAS O SUGERENCIAS
JORNADASTECNOLOGICAS@AGESIC.GUB.UY
