EWIG geht es weiter Ein Erfahrungsbericht

Ingo Kirchner

Institut für Meteorologie Freie Universität zu Berlin

4. November 2014



Inhaltsverzeichnis

- Forschungsdatenmanagement
- Das EWIG Projekt
- **3** MEVIS als Datenprojekt
- 4 Wie geht es weiter?



e-Science - Intelligent Openness

Welchen Herausforderungen müssen wir uns stellen, um dem aktuellen Forschungsrahmen Rechnung zu tragen?

→ Science as an Open Enterprise (Royal Society Report, 2012)

wichtige Forschungsdateneigenschaften ...

- zugänglich (accessible)
- bewertbar (assessable)
- verständlich (intelligible)
- verwendbar (usable)

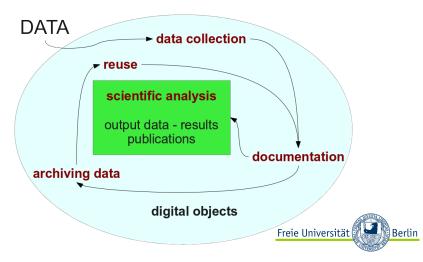


Rahmenbedingungen

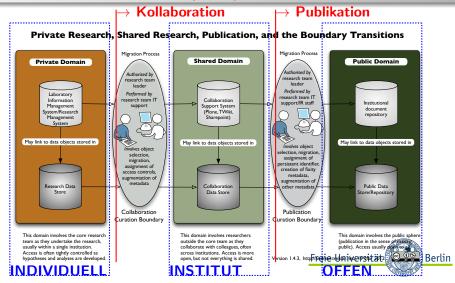
- → langfristige Sicherung der Forschungsdatenbestände
- → (fachübergreifende) Nachnutzung von Forschungsdaten
- \rightarrow Vernetzung von Datenbeständen
- → Empfehlung der DFG zur 10-jährigen Sicherung von Primärdaten
- → Konzepte: Lebenszyklus, Domänen und Übergänge



Lebenszyklus von Daten



Domänen nach Treloar (2012)



Vertiefung

Empfehlung von Quellen ...

Handbuch Forschungsdatenmanagement (Büttner, Hobohm, Müller, Bock+Herchen Verlag, Bad Honnef, 2011)

Wiki http://www.forschungsdaten.org/

Handreichung zum "Einstieg ins Forschungsdatenmanagement in den Geowissenschaften" (2014)



Umsetzung

Was kann auf Institutsebene im Sinne von INTELLIGENT OPENNESS getan werden?



Übersicht zum Projekt EWIG

Entwicklung von Workflowkomponenten für die Langzeitarchivierung von Forschungsdaten in den Geowissenschaften

Beteiligte ZIB, GFZ, IfM

Laufzeit Nov/2011-Okt/2014

Förderer DFG - Förderbereich Literaturversorgungs- und

InformationsSysteme (LIS)

Ressourcen 0.5 Wissenschaftler pro Einrichtung, SHKs



Forschungsfragen

? unsere TODO Liste

- Workflowkomponenten und Schnittstellen zur Langzeitarchivierung identifizieren
- Musterlösungen zur Übergabe von Forschungsdaten entwickeln
- Prozess der Langzeitarchivierung von kontinuierlich wachsenden Datensätzen beispielhaft implementieren
- "Wege in die Köpfe" beschreiten
- ! Welche Ergebnisse wurden erreicht?



Ergebnisse aus EWIG

in 3 Jahren Projektarbeit entstand ...

- Policy für Datenprojekte am IfM
 ... und deren Umsetzung in die Praxis
- "Einstieg ins Forschungsdatenmanagement in den Geowissenschaften" (Handreichung für Lehre und Forschung) ... eingesetzt in Bachelor Modul "Statistik und Programmierung"
- MEVIS-Datenprojekt und Portal
 ... exemplarische Umsetzung von "intelligent openness"



Policy zu Datenprojekten

Policy über die Organisation der Datenprojekte

(Sund Adl. 2013, Venion 3)

51 Dieses Dakument regelt die Veransvortlichkeiten bei der Verwaltung von Dampunjekter (DP) und enthält Einglichkungen zur Onganisation der Daten innerhalb eines DP. Anderungen an diesem

§2

Dis DV wender deit die eine zusammerbelagende Perkine inserhalt des vermäten Darerbereichen auf einer eingerer LINK Compy auf einen zusagneicht erwis Nazure, dere Darerbergsbrücken in Stemen der Ste

53

Ein neues DP kans eingesichtet werden, schald eine inhabliche und schaische Abgrenzung von Dass natwendig wird. Wens der dützt unsetzeige Bereich nebt als 5% des noch nerfügligkener Plattengkäten sehr zu der Jahr 16 e. Gezantlerenche im zumäuße Spiechtengob beträgt, mass die Einschausg durch des IT-Albri oder des geschältsfaltenelen Detecht nebstägt werden Gelders will bei einer Weipfelrung eine Benechtende DP zu. Das IT-Makr kam die Einschausg niese Dr.

84

Dis Dusequejet entialt de zwei Universitier "vorde" und "arch". Der Onter "vorde" diest als zeitweilig zu instreeder Arbeitsbereich für die Vorbereisung und Bearbeitung von Dates, die nach Absolltes der Arbeiten durch den Projektadiumistissen in des Order "arch" einsorden werden. Eine Bescheitung des Die Feligie in der Testaken "Jahren [Divin]BAZDME".

Eine Beschreibe §5

En EP visit von mindemen einem Wissenschafter genant. En Wissenschafter aus der Nazuspappe num als Euserprojekte warenordichte (EPV) bestimmt werden. Der EPV kann einen oder mehrere Stellvertreter bestimmen. Dies ist in der "README" des EP zu dekumenteren.

56

Aufstein des DPV

- dighen des DPA;
 song für eine optimale Nutzung des DP-durch regelmällige Überpatitung der DP-Aktiviktion
 dekumentiert das DP-in einer README-Dussi nach den vorgegebenen Erspfeblungen (siehe
- organisiers die Daten im "arch" Bereich und dokumentiers diese DP-specifischen Regeln
 song für eine konsistente Überleitung von Daten am dem "wark" in den "arch" Bereich
- mutat des DRAA für administrative Arbeiten im DP
 legt die Verfalborit von Daten im "work"-Bereich i
- zeigt Anderungen zum DP (Größenunpessungen, Verantwurtlichkeiter) in schriftlicher Form der IT-Administration an

§7 Jede Person mit einem Institutsaccount kann die Schreibrechte für ein DP bekannnen, wenn dies im Rahnen seiner Tätigkeit norwenlig wird. Der DPV des DP mass für einen Institutsaccount die Aufgeberen bestättigt.

88
Bir Nazanne eine DP wetzt die Amerikensung dieser Pulice voraus. Bei Missachtung die Policy

Committee eine DP wetzt die Amerikensung dieser Pulice voraus. Bei Missachtung die Policy

Committee eine DP wetzt die Amerikensung dieser Pulice voraus. Bei Missachtung der Policy

spesifischen Organisationregels, deren Einhaltung in der Veranzvertrag des DPV I Empfehlungen für den DPV und die Nutzer von DPs

- Der DPV hat die Verantwortung für einen seigfälligen Umgang mit dem DPAA. Es sollten nicht mehr als zwei Prosenen diesen Account benutzen. Es wird emploblen, das Enswurt den DPAA regelmaßig zu werben.
 Zur Demanchene der Betrandrichten inwerbalt einer DP-werben einzul riedlich die DD.
- Zur Überwachung der Platzonfrichung innerhalb eines DP werden einmal diglich de DP
 ausgewerte und eine Belegungsline für jelech Natuer des DP erungs; Diese Lies befallet
 sich im Diesepsych sierte (ringseich Nateur, zeleste (DPN) (LISENANEE) und ersicht in
 der ersten Spale die Diesepsyche, in der zweiten den kompleten Namen derr Datet. Diese
 Basten sind Ganzellag der Statistik aureit hapt, ...
- Der DFV sollte von Bestatzung eines DP die Deparkoutonengeln des "arch"-dierriches in de JEEADMS" diskumentieren. Beispiele für eine Gestaltung der Ontwerstratzur befinden sich auf des belösselne des Jonater duppel."
- Der DPV kam jederzeit Deins am dem Datesprojekt Brichen. Dies sellte jedoch immer nach Alsprache mit den DP-Nazons orfolgen.

→ http://www.geo.fu-berlin.de/met/internes/datenprojekte/



Policy

minimales Regelwerk zur Organisation des **institutionellen Repositoriums** am IfM - "Datenpool"

- Verantwortlichkeiten
- Zugriffsrechte
- Gliederung/Struktur der Plattenbereiche
- → wirtschaftliche Verteilung und Verwaltung der IT-Ressourcen (ca. 280 TB momentan, Wiederbeschaffungswert ca. 100 T€)



Wege in die Köpfe - 3./4. Juli 2014



Workshop zur Entwicklung einer Handreichung für die Lehre



MEVIS

Messwert**E**rfassungs-, **V**erarbeitungs- und **I**nformations**S**ystem (Fa. Thies)

- ... Einbindung in das institutionelle Repositorium
- ... flexibler Zugang zu den Daten
- \rightarrow Erweiterungen ...
 - Datenprojekt und Archivierung "/daten/mevis/arch/"
 - Softwarestack "mevis-lib"
 - Dokumentation (Sensornetz, Datenportal, Software)
 - MEVIS-Portal http://mevis-www.met.fu-berlin.de/



Arbeitsschritte

- Analyse der Ausgangslage
- ② Gestaltung des Workflows vom Sensornetz bis zu einer Datenablage, die den Rahmenbedingungen von "intelligent openness" genügt
- Implementierung der Komponenten des Systems im institutionellen Repositorium



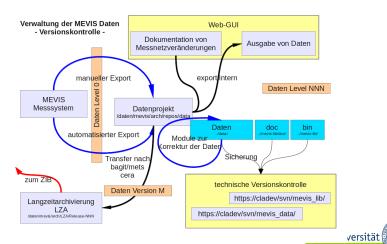
Ausgangslage

- heterogenes Sensornetzwerk
- abgeschlossener Datensammler, kein direkter Zugang zu den Messwerten
- Rohdaten sind Minutenwerte

Aufgabe: Transfer der Rohdaten aus dem Sensorsystem in ein Langzeitarchiv



Datenfluss - MEVIS → /daten/mevis/



Berlin

Bereitstellung der Daten

- möglichst flexibel
- nicht frei zugänglich
- transparent für die Nutzer
- effizient, mit wenig Personaleinsatz
- reproduzierbare Auslieferung



Lösungsansatz

Die Daten des Sensornetzwerkes können auf zwei Wegen genutzt werden ...

- lacktriangledown auf der Kommandozeile ightarrow Python Programmbibliothek
- ② Webbasiert → Mevis-Portal



Struktur des Datenprojektes

- /daten/mevis/arch/repos/data/
 Minutenwerte nach Station und Sensor sortiert, pro Datei immer ein Tag erfaßt, Datenformat ASCII
- /daten/mevis/arch/repos/mevis-lib/
 Dokumentation, Python-Scripte, Qualitätsmodule
- /daten/mevis/arch/LTA/
 Zusammenstellung der Daten für den Transfer in ein LTA
- → Ausgabe der Daten als Tabelle (ASCII)
- → Einbindung in Python über die mevis-Klasse



Statistik

Anzahl der Stationen 12 (von 13) Anzahl der Messstellen 17 (von 19)

Anzahl von Sensoren 104 verschiedene

verschiedene Größen 47

verschiedene Elemente ca. 20

Zeitraum Feb/1997 - Jul/2014

Speicherplatz ca. 130 GB

Dateien ca. 541000



Hauptstation

FB-Messturm (2)

Station	Sensoren	Zeitraum	Tage			
Steglitz (Feb/1997-Jul/2014)						
Botanischer Garten (1)	11	Feb/1997 - Jul/2014	6392			
Botanischer Garten (2)	9	Feb/2008 - Jul/2014	2374			
Fichtenberg	16	Feb/1999 - Dez/2001	1066			
FB-Messturm (1)	16	Feb/2001 - Dez/2013	4718			
FB-Messwiese (1)	6	Feb/2001 - Dez/2010	3622			
FB-Messwiese (2)	1	Mär/2010 - Jul/2014	1616			
nicht erfaßte Stationen						
Albrecht Thaer Weg						

Freie Universität Berlin

Netzwerk Stationen

Station	Sensoren	Zeitraum	Tage
Steglitz	bis 16	Feb/ 1997 - Jul/2014	6392
Gatow	5	Feb/ 1997 - Jul/2014	6391
Tempelhof	14	Feb/ 1997 - Dez/ <i>2011</i>	5448
Marzahn	10	Feb/1999 - Mai/2014	5589
Tegel Forstamt	6	Feb/1999 - Jul/2014	5661
Fasanenstrasse	6	Feb/2000 - Jul/2014	5296
Wannsee	9	Feb/2003 - Jul/2014	4201
Planetarium	4	Feb/2005 - Jul/2014	3453
Pichelsdorf	9	Feb/2007 - Jul/2014	2737
Funkturm	6	Feb/2009 - Dez/2010	700
Tegeler See	7	Jan/2009 - Jul/2014	2038
Mueggelsee	9	Feb/2011 - Jul/2014	1278

Mevis-Portal

Was bietet die WebGUI?

- 1 flexible Auswahl der Daten nach Station, Sensor, Jahr
- Peinauswahl des Zeitraums
- 3 Zusammenstellung der ausgewählten Daten im Hintergrund
- Okumentation der Stationen
- Anleitung und Dokumentation des Datenprojekts
 - → kurze Demonstration
 - http://mevis-www.met.fu-berlin.de
- Aktualisierung der Historie und Sensorbeschreibung



Qualitätsmanagement

- Bereitstellung von Python-Modulen in der "mevis-lib"
- Datenablage berücksichtigt Buchführung über Korrekturen einzelner Werte
- Markierung von Qualitätsstufen möglich
- Korrekturprozess muss manuell durchgeführt werden, QM-Module liefern Entscheidungshilfe durch Markierung von zweifelhaften Messungen



Zur Diskussion steht ...

- Wo besteht Entwicklungspotential?
- Welche Aufgaben sind in Routine zu überführen?
- Wer iibernimmt welche Rolle?



Vorschläge

- Anwendung der bestehenden QM-Module auf die wichtigsten meteorologischen Größen aller Stationen
- Erstellung eines geprüften Datensatzes für den Zeitraum 1997-2014
 - \rightarrow Datenveröffentlichung
- kontinuierliche Ergänzung der Daten (monatlich)
- Erweiterung der QM-Module
 - → Bachelor- Masterarbeiten
- Portalerweiterung zur Dokumentation der Messnetzhistorie und der Stationen



Danke für die Aufmerksamkeit

