

Recherchieren zu einem Wissen- schaftlichen (Informatik-)Thema

Ulf Leser

Inhalt

- Übersicht
- Wissenschaftliche Publikationen
- Bewertung von Publikationen
- Ressourcen und Techniken
- Literatursammlung erstellen und managen

Wissenschaftliches Thema

- In (Informatik-)Seminaren werden Themen meist gestellt
 - Ein Problem, eine Methode, ein Vergleich
 - Meist Paper und / oder kurze Erklärung
- **Granularität**: Themen können sehr breit oder sehr eng sein
 - Breit: Übersichtsarbeiten, geringe technische Tiefe
 - Eng: Spezialarbeiten, hohe technische Tiefe
- Themen stehen meist nicht genau fest
 - Recherche ergibt neue Aspekte – Themenanpassung
 - Hier können **persönliche Präferenzen** eingebracht werden
- Anders: Recherchieren zur Themenfindung
 - Explorativ versus zielgerichtet

Ziel einer Recherche

- Im Ergebnis der Recherche kennt man
 - Verschiedene **Aspekte des Problems**
 - Die verschiedenen Ansätze zur Lösung
 - Die **wichtigste Literatur** zum Thema
 - **Eigener Schwerpunkt** und welche Literatur man verwenden wird
- Vollständigkeit
 - IdR ist es unmöglich, alle Literatur zum Thema zu sichten
 - Bewertung der **Relevanz** und Auswahl notwendig
 - Teilweise macht man das selbst (lesen), teilweise vertraut man anderen (Wikipedia, Buch, Übersichtsartikeln, Datenbanken, ...)
 - Wichtig ist **gestufte Bewertung**: Titel/Autoren, Zitate, Erscheinungsort, Abstract, querlesen ...
 - Literaturliste immer mit dem Betreuer besprechen

Allgemeines Vorgehen

- Vor der genauen Recherche muss Thema (intuitiv) verstanden sein
 - ... sonst kann man Relevanz nicht beurteilen
 - Um was geht es in dem Problem?
 - Für was wird eine Methode verwendet?
- Prozesssicht
 - Recherche verläuft iterativ
 - Man sucht, liest, sucht mit anderen Begriffen, liest, folgt Links, ...
 - Management des Prozesses wichtig
 - Verwaltung und Systematisierung des Gefundenen
 - Beim späteren Schreiben ergeben sich neue Aspekte
 - Ergänzende Recherchen
 - Ggf. auch Anpassung des Themas möglich oder notwendig

Eng gefasste Themen

- Manches Seminarthema besteht aus einem Paper
- Das heisst nicht, dass man nicht auch andere Paper suchen und lesen muss!
 - Andere Ansätze kennenlernen
 - Übersicht gewinnen
 - Zugeteiltes Paper besser einschätzen (was ist besser / neu / ...)

Beispiel

- Breit gefasst: Multidimensionale Indexstrukturen
 - Etabliertes Thema; es gibt Bücher und Übersichtsartikel; es gibt 1000+ Originalarbeiten; es gibt andere Seminararbeiten dazu im Web; es gibt Wikipedia Artikel; es gibt kommerzielle Produkte; ...
 - Übersicht gefragt: Was wird indiziert, welche Suchen werden unterstützt, welche grossen Klassen von Ansätzen gibt es, was sind deren Vor- und Nachteile, wo wurden sie schon mal verglichen, ...
- Eng gefasst: kdb-Trees
 - Sehr spezielles Thema; vielleicht eine (kurze) Erwähnung in einem Buch; vielleicht 10-20 wirklich relevante Arbeiten, die man vor allem in Spezialdatenbanken findet; kaum Erwähnung im Web; ...
 - Details sind gefragt: Wie funktioniert Löschen, welche Komplexität haben alle Operationen, wo gibt es empirische Untersuchungen, sind die Abhängig von den Daten, gibt es aktuelle Weiterentwicklungen, ...
- Themenanpassung (MDI)
 - Punkte / Flächen/Körper? Exakte / Ähnlichkeitssuche? Memory / Disk?
 - Was interessiert Sie mehr?

Inhalt

- Übersicht
- Wissenschaftliche Publikationen
- Bewertung von Publikationen
- Ressourcen und Techniken
- Literatursammlung erstellen und managen

Arten von Publikationen

- Zentrales Merkmal: Peer-review or not
- Peer-reviewed: Journale, Konferenzen, Workshops
 - In anderen Fächern ist das anders!
 - Informatikspezifisch: Konferenzen fast wichtiger als Journale
- Nicht: Bücher, Buchkapitel, (Technical) Reports
 - Reports: Früher pro Institut, heute eher internationale, fachspezifische Repositorien (arXiv, corr)
- Nicht wissenschaftlich: Blogs, White Paper, Wikipedia
- Sonderfälle
 - Dissertationen, Diplom- und Seminararbeiten (Reports)
 - Poster, Meeting-Abstracts (in der Informatik kaum existent)
 - Vortragsfolien, Vorlesungen, auch Video

Peer-Review

- „Gute“ oder „neue“ Wissenschaft nicht objektiv definierbar
- Entscheidung soll durch Community getroffen werden
- Peer-Review: Paper werden von 2-3 ExpertInnen bewertet
 - Ablehnung, Annahme, Revision
 - Einschätzung der Relevanz, Neuheit, Qualität des Textes
 - Unterschiedliche Anforderungen je nach Erscheinungsort
 - Nature: Extrem hoch, insb. Neuheit und Allgemeinrelevanz
 - Kleine Workshops: Eher niedrig, oft sehr spezielle Ergebnisse
- Vielfältige Kritik
 - ExpertInnen die keine sind; schlampiges Lesen; Unterdrückung von Konkurrenz (single-blind); Trend zu Modethemen und inkrementellen Ergebnissen; idR keine Ergebnisvalidierung; ...
- Aber bestes bekanntes Verfahren

WikiPedia

- Zur frühen Recherche sehr nützlich
- Erfahrungsgemäß (in Informatik) meistens korrekt, aber nur **geringe Themenabdeckung oder Tiefe**
- Als Referenz allgemein **nicht** akzeptiert; zum Finden von Referenzen schon

Übersichtsartikel / Benchmarks

- Zu nahezu allen Themen erscheinen regelmäßig Übersichtsartikel (surveys, reviews)
 - Vor allem als Buchkapitel / in Journals
- Unterschiedliche Qualität und Tiefe
- Gute und aktuelle Surveys sind ein Segen und die halbe Miete für eine Seminararbeit (oder eine BA)
- Meistens sehr lange und nützliche Literaturlisten
- Für praktische Themen sehr relevant: Empirische Übersichts- und Vergleichsarbeiten (Benchmarks)

Lexika

- Lange Zeit bedeutungslos
- In den letzten Jahren aber wieder etwas populärer
 - Encyclopedia of ... Database Systems (Springer): „Comprehensive reference to about 1,400 entries, covering key concepts and terms in the broad field of database systems.“
 - Synthesis Lectures on ... Data Management (Morgan Claypool)
 - ...

Englisch, Deutsch, ...

- Alles wichtige, aktuelle ist Englisch
- Deutsche Lehrbücher als Einstieg

Inhalt

- Übersicht
- Wissenschaftliche Publikationen
- Bewertung von Publikationen
- Ressourcen und Techniken
- Literatursammlung erstellen und managen

Impact Factor, Zitationen

- Qualität ist nicht binär
 - Erhebliche Unterschiede auch zwischen peer-reviewed Papern
- Wichtiges Indiz: Erscheinungsort und Autor
 - Welches Journal, welche Konferenz
 - Was keinen **eindeutigen Autor** hat, zählt überhaupt nicht
- Typische Qualitätsmaße
 - **Impact Factor**: Durchschnittliche Zahl Zitierungen eines Papers in diesem Journal nach 5 Jahren; Wertebereich 0-32
 - Kritik: **Nicht alle Paper eines Journals gleich gut**; Themen mit kleinere Communities haben weniger Zitate; **Fächerunterschiede**; ...
 - Alternative: **Zitationszahlen pro Paper**
 - Google Scholar, Microsoft Academic Search, CiteSeer, Web-of-Science
 - Früher: Verlag

Wem trauen?

- Zentral: **Zahl der Zitate**
 - Gewichtet nach Jahr – 10 pro Jahr ist ganz ordentlich
 - Mit etwas Exploration ein Gefühl für das Thema bekommen
 - Viele Paper mit vielen Zitierungen?
 - Spezialgebiet mit insgesamt wenig Zitierungen?
 - Bringt einen Bias: „rich get richer“
- Auch wichtig: Erscheinungsort
 - Suche nach „Erschienen in“ und sehen, wie oft Paper typischerweise zitiert werden
 - Vorsicht vor Abkürzungen und Schreibweisen
- Auch wichtig: Autor
 - Verlangt viel Erfahrung, starker Bias gegen Newcomer

Welchen Zahlen trauen?

The image shows a desktop environment with three open browser windows:

- Google search:** URL: [citeseरx.ist.psu.edu/search?q=author%3Aleser&sort=cite&t=doc](https://citeseerx.ist.psu.edu/search?q=author%3Aleser&sort=cite&t=doc). The results page shows 10 of 206 items, including a section on "Querying Distributed" and "Quality-driven Integration".
- CiteSeerX search results:** URL: [www.ncbi.nlm.nih.gov/pubmed/?term=leser-u\[au\]](https://www.ncbi.nlm.nih.gov/pubmed/?term=leser-u[au]). The results page shows 1 to 20 of 71 items, with a sidebar for "Article types" (Clinical Trial, Review, Customize ...), "Text availability" (Abstract, Free full text, Full text), "PubMed Commons" (Reader comments, Trending articles), "Publication dates" (5 years, 10 years, Custom range...), and "Species" (Humans, Other Animals). The results list includes items like "Robust In-Silico identification of cancer cell lines based on next generation sequencing" and "Estimating genome-wide regulatory activity from multi-omics data sets using mathematical optimization".
- PubMed search:** URL: [www.ncbi.nlm.nih.gov/pubmed/?term=leser-u\[au\]](https://www.ncbi.nlm.nih.gov/pubmed/?term=leser-u[au]). The results page shows 1 to 20 of 71 items, with a sidebar for "Format" (Summary), "Sort by" (Most Recent), "Per page" (20), and "Send to". The results list includes items like "Robust In-Silico identification of cancer cell lines based on next generation sequencing" and "Estimating genome-wide regulatory activity from multi-omics data sets using mathematical optimization".

Welchen Zahle trauen?

The image shows two side-by-side screenshots of Google Scholar search results. The left screenshot is for 'Manfred Reichert' and the right is for 'Schobel: Towards flexible mobile data collection'.

Left Screenshot (Manfred Reichert):

- Message from the CeScop/ProMos 2016 Workshop
- Ulmer Informatik-Berichte
- Business Process Management Workshops: BPM Workshops, Innsbruck, Austria, August 31–September 1, 2016
- Die KINDEX-App-ein Instrument zur Erfassung und Analyse von psychosozialen Belastungen bei Schwangere, Gynäkologinnen, Hebammen und in Frauenklinik
- Context-Based Assignment and Execution of Human Tasks in Mobile Services
- End-user programming of mobile services: empowering users to implement mobile data collection applications
- Using Wearables in the Context of Chronic Disease
- Using Mobile Serious Games in the Context of Chronic Disease: A Concept for the Treatment of Tinnitus
- Towards flexible mobile data collection in healthcare
- Considering Social Distance as an Influence Factor in Business Process Modeling
- Controlling Time-Awareness in Modularized Workflows

Right Screenshot (Schobel: Towards flexible mobile data collection):

- A Configurator Component for End-User Defined Mobile Data Collection
- A mobile service engine enabling complex data collection applications
- A lightweight process engine for enabling advanced mobile applications
- Konzeption und Realisierung einer konfigurierbaren Plattform zur flexiblen Datenerhebung mittels moderner Webtechnologien
- Approximate Sensory Data Collection: A Survey
- Evaluating a Configurator Application for Modeling Data Collection Instruments: An Experimental Study
- Design and Implementation of a NoSQL-concept for an international and multicentral clinical database
- Konzeption und Realisierung einer mobilen Anwendung zur Untersuchung der menschlichen Lokalisationsfähigkeit

A large blue oval highlights the first four results from the right screenshot, which are all related to mobile data collection and process engines.

Spezifika eines Fachs

	Informatik	Life Sciences	Humanities
Wo wird publiziert	Konferenzen, Workshops, Journals, TRs	Nur Journals	Bücher
Wie wird bewertet	Zitierungen, Ort	Impact Factor	Autor
Wo wird gesucht	Google Scholar (ResearchGate?)	Web of Science	Bibliothek
Was ist „viel“	100 pro Jahr	1000 pro Jahr	10 pro Jahr
Autorenlisten	2-5	Oft >20	1
Struktur von Papern	Frei	Fest (Intro, Methods, Results, Diskussion)	Frei

Open Access

- Idee: Artikel lesen umsonst, publizieren kostet Geld
 - Traditionell: Publizieren ist umsonst, Lesen kostet Geld
- Das ist **unabhängig von Peer-Review**
 - Die meisten Open Access Journale sind peer-reviewed
- Das ist **unabhängig von kommerziellen Interessen**
 - Die meisten Open Access Journale sind kommerziell orientiert
- Erheblicher politischer Druck zu Open Access
- Informatik: Bisher keine relevanten OA-Journale
 - Autoren stellen traditionell viele Artikel frei zur Verfügung
 - Workshop/Konferenz-Beiträge sind fast immer frei verfügbar
 - Bedeutung von **TR-Repositorien**

Alter – Wann ist Literatur nicht mehr aktuell?

- So alt ist die Informatik nicht
 - Viele grundlegende Arbeiten aus den 60ziger – 80ziger
- Theoretische Resultate (Beweise) halten „ewig“
- Methodische Resultate halten lange
 - Geschäftsmodelle, Best Practise, Algorithmen, Modellierungsansätze, ...
- Empirische Resultate können schnell veralten
 - Besser nicht älter als 10 Jahre
 - Hauptspeicher - andere Indexverfahren
 - Cachelines – Scan statt Index
 - Breitbandinternet – Berechnungen verteilen
 - ...

Inhalt

- Übersicht
- Wissenschaftliche Publikationen
- Bewertung von Publikationen
- **Ressourcen und Techniken**
- Literatursammlung erstellen und managen

Recherche-Datenbanken

- Google Scholar / (Microsoft Academic Search) / Citeseer
 - Volltextindexierung wissenschaftlicher Veröffentlichungen
 - GS: Ziemlich **vollständig** und aktuell
 - Wichtiges Feature: **Zitierende Arbeiten**
 - Voll automatisch; viele Qualitätsmängel
 - Zugriff auf Volltexte über Links
 - Innerhalb der HU weit mehr Content als außerhalb
 - Bibliographische Informationen oft unvollständig
 - Selber nach-recherchieren
- DBLP
 - Manuell gepflegt, Fokus auf DB+LP
 - Unvollständig, keine Volltexte, Links auf PDFs
 - Sehr gut bzgl. **bibliographischer Daten**

Weitere Datenbanken

- ResearchGate
 - Closed, eventuell mehr PDF, Zugriffsregeln unklar, Zitierungszahlen unzuverlässig, manuell kuriert (Autoren), dubiose „Scores“ für Autoren
- PubAnnotator, Mendely, ...
- ACM-DL, IEEE-Explore, Springer Link, ...
- Web-of Science, Scopus, ...
- „First pirate ...“ sci-hub.io

Bibliotheken

- Zur Recherche wenig nutzbringend
- Sehr gut als **Arbeitsort**
- Sehr wichtig zur Organisation des Zugriffs auf **lizenzierten Content**
 - eBooks, online-subscriptions, ...

Recherche Techniken

- Suchfeature benutzen
 - Keywords, Phrasen, Negation
 - Suche nach Autoren
 - **Suche nach zitierenden Arbeiten**
 - **Suche nach Jahren**
 - [Suche nach Erscheinungsort]
- Auch wichtig: Wichtige **Referenzen** in guten Papern

Gestufte Bewertung

- Man muss **vieles ansehen**, aber das meisten **nur kurz**
- Erste Einschätzung: Titel, Ort, Zitierungen (C)
 - Journal oder Konferenz; bei Zahl Zitierungen das Jahr beachten
- Zweite Einschätzung: **Abstract** (C)
 - Ggf schnell aufhören, wenn erkennbar irrelevant
- Dritte Einschätzung: **Paper querlesen** (B)
 - Welches Problem, welcher Ansatz, welche Daten, welche Resultate?
 - Algorithmen, Beweise, Formeln überspringen
 - Paper mit Stichworten **in Liste aufnehmen** („Cite“ – kopieren)
- Vierte Einschätzung: **Paper genau lesen** (A)
 - Eigene Zusammenfassung **in Liste aufnehmen**

Iterativer Prozess

- Explorationsphase: Liste B-Paper erstellen
 - Keywortsuche, Surveys suchen, normierte Zitationszahlen beachten
 - Man findet die „seminal paper“ und erhält Übersicht
 - Paper eher schnell beurteilen, erstmal sammeln
- Komplettierungsphase: Die A-Paper finden
 - Wichtigste Paper aus der B-Gruppe
 - Auch gezielte weitere Suchen
 - Aktuelle Arbeiten, die A/B-Paper zitieren
 - Wichtige Arbeiten aus Referenzlisten von A/B-Papern
 - Führt zu weiteren A und B Papern (ständig bewerten)
- Verwendungsphase
 - Kann zu gezielten weiteren Recherchen führen
 - Aber nicht verlieren! $|A|=10$ ist viel; ggf. Betreuer fragen

Life-Beispiel: SIMD in Datenbanken

- Autorensuche
- Erscheinungsjahr
- Zitierende Arbeiten
- Versionen
- Bibliographische Informationen
- [Related Articles, Web of Science]

Data broadcasting in SIMD computers

D Nassimi, S Sahni - Computers, IEEE Transactions on, 1981 - ieeexplore.ieee.org

... The PE's are **indexed** 0 through $TV - 1$ and may be referenced as PE ... 2^k -block independent of the remaining 2^k -blocks (ie, as if each 2^k -block defined a separate SIMD computer ... Complexity of Rank: 1) MCCs with row-major **indexing**: Let $TV = n^{k^*} = 2P$ be the number of PE's in a ...

Cited by 324 Related articles All 3 versions Web of Science: 134 Cite Save More

[PDF] from computer.org

Volltext

Implementing database operations using SIMD instructions

J Zhou, KA Ross - Proceedings of the 2002 ACM SIGMOD international ..., 2002 - dl.acm.org

... When one returns all matches, we write the results to an array called **result**, **indexed** by a ... resident **indexes**, as well as to the layout of a disk page within disk-based **indexes**. In this section, we study techniques for employing SIMD instructions to make index traversal more efficient ...

Cited by 142 Related articles All 11 versions Cite Save More

[PDF] from columbia.edu

SIMD-scan: ultra fast in-memory table scan using on-chip vector processing units

T Willhalm, N Popovici, Y Boshmaf, H Plattner... - Proceedings of the ..., 2009 - dl.acm.org

... In this paper, we assume 64-bit little-endian architecture with **indexing** starting at and increasing by ... For example, if the compressed data represents an array of ascending integers (**indexes**) starting from "0d" till ... the index array would be "1d, 2d, 3d, 4d, 5d" for a 0-**indexed** array. ...

Cited by 99 Related articles All 5 versions Cite Save

[PDF] from ubc.ca

Volltext

Inhalt

- Übersicht
- Wissenschaftliche Publikationen
- Bewertung von Publikationen
- Ressourcen und Techniken
- Literaturliste managen

Aufbereiten einer Textsammlung

- Notizen und Zusammenfassungen zu allen A und B Papern machen und verwalten
- Bibliographische Informationen gleich in hoher Qualität sammeln
- Strukturieren: Nach Problemvarianten, nach verwendeten Datensätzen, nach Architektur, nach Denkschule, ...
- Individuelle Schlagworthierarchie sinnvoll
 - Und notwendig bei Dissertationen
- Spezielle Software benutzen (später)

Exzerpte erstellen

- Eigene Worte verwenden, nicht Abstract kopieren
- Texte drucken und markieren, dann zusammenfassen
- Systematik erstellen (Farben) – Kernaussage, Kritikpunkt, experimentelle Ergebnisse, ...
- A Paper ausführlich beschreiben, B Paper nur kurz
- Gute Zusammenfassungen kann man ggf. in die Seminararbeit übernehmen
 - Meist sind die aber zu kurz

Zum Zitieren

- Alle: Autoren, Titel, Jahr
- Konferenzen/Workshops: Name der Konferenz, Ort
- Journal: Ausgabe (volume, issue), Seitenzahl
- Report (auch Dissertation, DA ...): Institution, Nummer

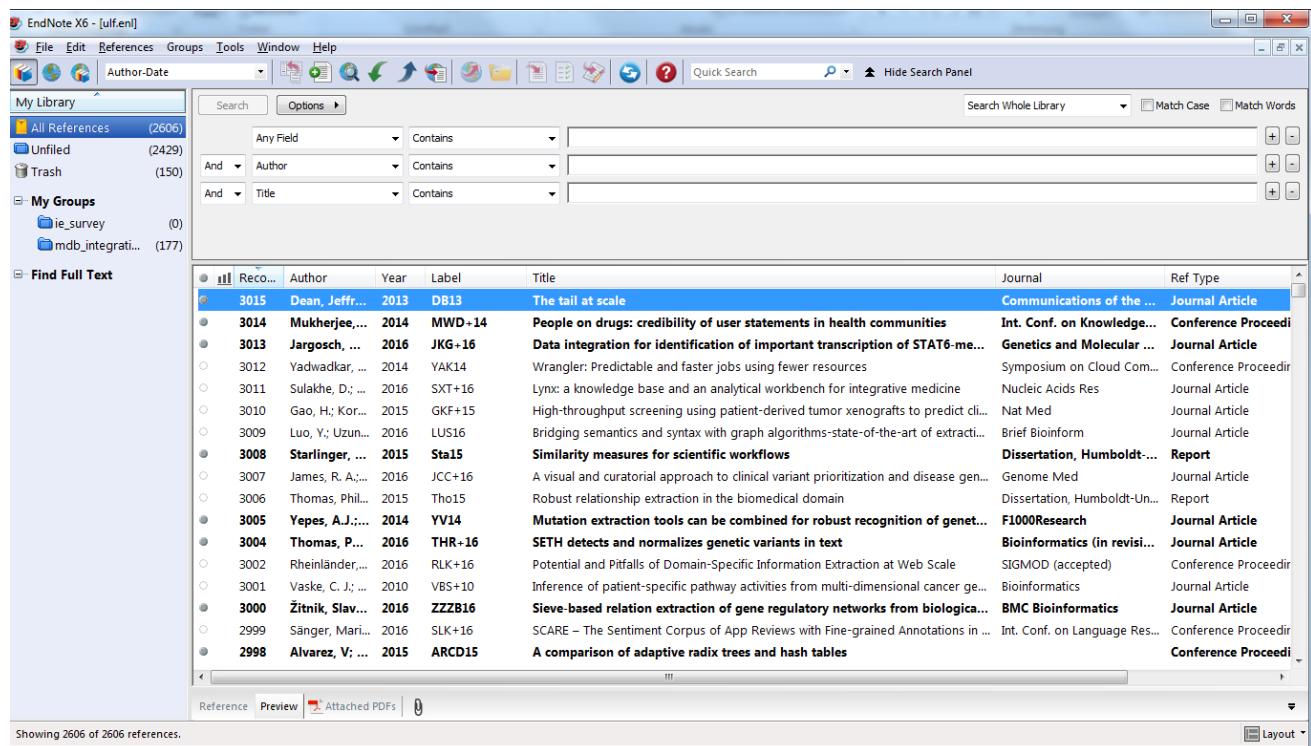
- Möglich: DOI
- Nicht in Referenzliste: URL
- Nützlich zur Suche: Abstract
- Nützlich zum Nachsehen: PDF

Management von Literatur

- Spezielle Software zum
 - Datenbank für Literatur (Bibliographie, Link, Verschlagwortung, ...)
 - Ggf mit PDF Verwaltung und Volltextindexen
 - Ggf. automatische Extraktion bibliographischer Daten aus Webseiten
 - Formatierung von Referenzen in Texten nach Vorlagen
 - Word Plug-In, BibRef
 - Sortieren, suchen, filtern
 - Zugriff auf Datenbanken (PubMed)
- Endnote (Campuslizenz), Bibliographix, Citavi, jab-ref, ...
- Online-Systeme: Mendely, zetoro, ...

Live-Beispiel

- Suchen
- Zugriff PubMed
- Word-Formatierung
- Referenzstile
- Formatierter Export
- BibTex-Export



The screenshot shows the EndNote X6 software interface. The top menu bar includes File, Edit, References, Groups, Tools, Window, and Help. The toolbar contains various icons for file operations like Open, Save, Print, and Insert. The left sidebar shows 'My Library' with 'All References (2606)', 'Unfiled (2429)', and 'Trash (150)'. It also displays 'My Groups' with 'ie_survey (0)' and 'mdb_integrati... (177)'. A search panel is open with three search criteria: 'Any Field Contains' (empty), 'Author Contains' (empty), and 'Title Contains' (empty). The main pane lists 2606 references in a table with columns: Rec... (checkbox), Author, Year, Label, Title, Journal, and Ref Type. The first few entries are:

Rec...	Author	Year	Label	Title	Journal	Ref Type
3015	Dean, Jeff...	2013	DB13	The tail at scale	Communications of the ...	Journal Article
3014	Mukherjee, ...	2014	MWD-14	People or drugs: credibility of user statements in health communities	Int. Conf. on Knowledge...	Conference Proceedi...
3013	Jargosch, ...	2016	JKG-16	Data integration for identification of important transcription of STAT6-me...	Genetics and Molecular ...	Journal Article

At the bottom, a status bar indicates 'Showing 2606 of 2606 references.'