Computerlinguistik I

Vorlesung im WiSe 2018/19
(M-GSW-09)

Prof. Dr. Udo Hahn

Lehrstuhl für Computerlinguistik
Institut für Germanistische Sprachwissenschaft
Friedrich-Schiller-Universität Jena

http://www.julielab.de

Allgemeine Hinweise

- Vorlesung: Do, 10-12h (Fürstengrb.1, SR 275)
- Übung zV: Mo, 8-10h (Fürstengrb.1, SR 275)
  - beginnt am 22.10.
- Vorlesungsmaterialien im Netz
  - http://www.julielab.de/ ⇨ „Students“
- M-GSW-09 besteht aus VL+ÜB und Seminar!
- Sprechstunde: Mi, 12-13h, bA (FG 30, 004)
- Email: udo.hahn@uni-jena.de
- URL: http://www.julielab.de
- Fachliteratur ist überwiegend in Englisch

Bitte …

- … Handys/Smartphones ausschalten
- … 90 Minuten ohne Mail-Check sind möglich

  „Digital detox“
- … kein Picknick

Institut für Germanistische Sprachwissenschaft der FSU Jena

- Lehrstuhl für Theoretische Linguistik – Grammatiktheorie
  - Prof. Dr. Peter Gallmann – n.n
- Lehrstuhl für Angewandte Linguistik – Computerlinguistik
  - Prof. Dr. Udo Hahn
- Professur für Pragmatik
  - Prof. Dr. Pia Bergmann
- Professur für Phonetik & Sprechwissenschaft
  - Prof. Dr. Adrian Simpson
- Professur für Geschichte der deutschen Sprache
  - Prof. Dr. Eckhard Meineke

Computerlinguistik in Jena (1/2)

- Institutionell: Teil der Germanistischen Sprachwissenschaft
  - aber einzelsprachübergreifende Methodik
  - besondere Anwendungsdomänen:
    - Naturwissenschaften: Biologie + Medizin
    - Sozial- und Wirtschaftswissenschaft
    - Digital Humanities
- Integration in die Informatik:

  Neben- bzw. Anwendungsfach für
    - B.Sc.: Informatik, Angewandte Informatik
    - M.Sc.: Informatik, Computational Science

Computerlinguistik in Jena (2/2)

- Aktive Forschergruppe
  - Lehrstuhl für Computerlinguistik = Jena University Language & Information Engineering (JULIE) Lab
    - Hohe internationale Visibilität (Publikationsdichte)
  - Deutsche Forschungsgemeinschaft (DFG)
    - Aktuell: (1/5) SFB 1076 AquaDiva – Biodiversität in der Critical Zone
    - Aktuell: (1/5) Graduiertenkolleg Modell ‚Romantik' [Digital Humanities]
  - Bundesministerium für Bildung & Forschung (BMBF)
    - Aktuell: (1/7/26) Nationale Förderinitiative „Systemmedizin" (J–L–AC)
    - Frühere Projekte: Forschungs-Cluster JenAge – Nationaler Forschungskern, StemNet
  - Förderinitiativen der Europäischen Union
    - Frühere Projekte: MANTRA (SA), CALBC (SA), BOOTStrep (STREP), ..
- Ausgründung von Start-up-Firmen
  - *Averbis, TexKnowlogy*
- Jobs, Jobs, Jobs … etwa als studentische Hilfskraft
- Themen, Themen, Themen … BA- oder MA-Arbeit, Dissertation

Weitere Veranstaltungen

- **Seminar zu M-GSW-09**
  - **Machine Reading – WWW-skalierbares automatisches Textverstehen**
  - **Do, 16-18, Fürstengraben 1, SR 164**

Kleiner Exkurs zum Thema “Wissenschaftliche Exzellenz”

1.Exzellenz initiative (2006-07)

87 deutsche Universitäten

44 in Förderlinien

FSU Jena: 1 Graduiertenschule: Jena School for Microbial Communication

9 Elite-Universitäten (I)
(FUB, FR, GÖ, HD, KA, KN, MUM,TUM, RWTH AC)

2.Exzellenz-initiative (2010-12)

http://de.wikipedia.org/wiki/Exzellenzinitiative

87 deutsche Universitäten

11+45+43 = 89 in Förderlinien

FSU Jena: 1 Graduiertenschule:
Jena School for
Microbial Communication

9 Elite-Universitäten (I)
(FUB, FR, GÖ, HD, KA, KN,
MUM, RWTH AA, TUM)

11 Elite-Universitäten (II)
(TUDD, FUB, HB, HUB, HD, K, KN,
MUM , TUM, RWTH AC, TÜ)

3.Exzellenz-initiative (2017-22)

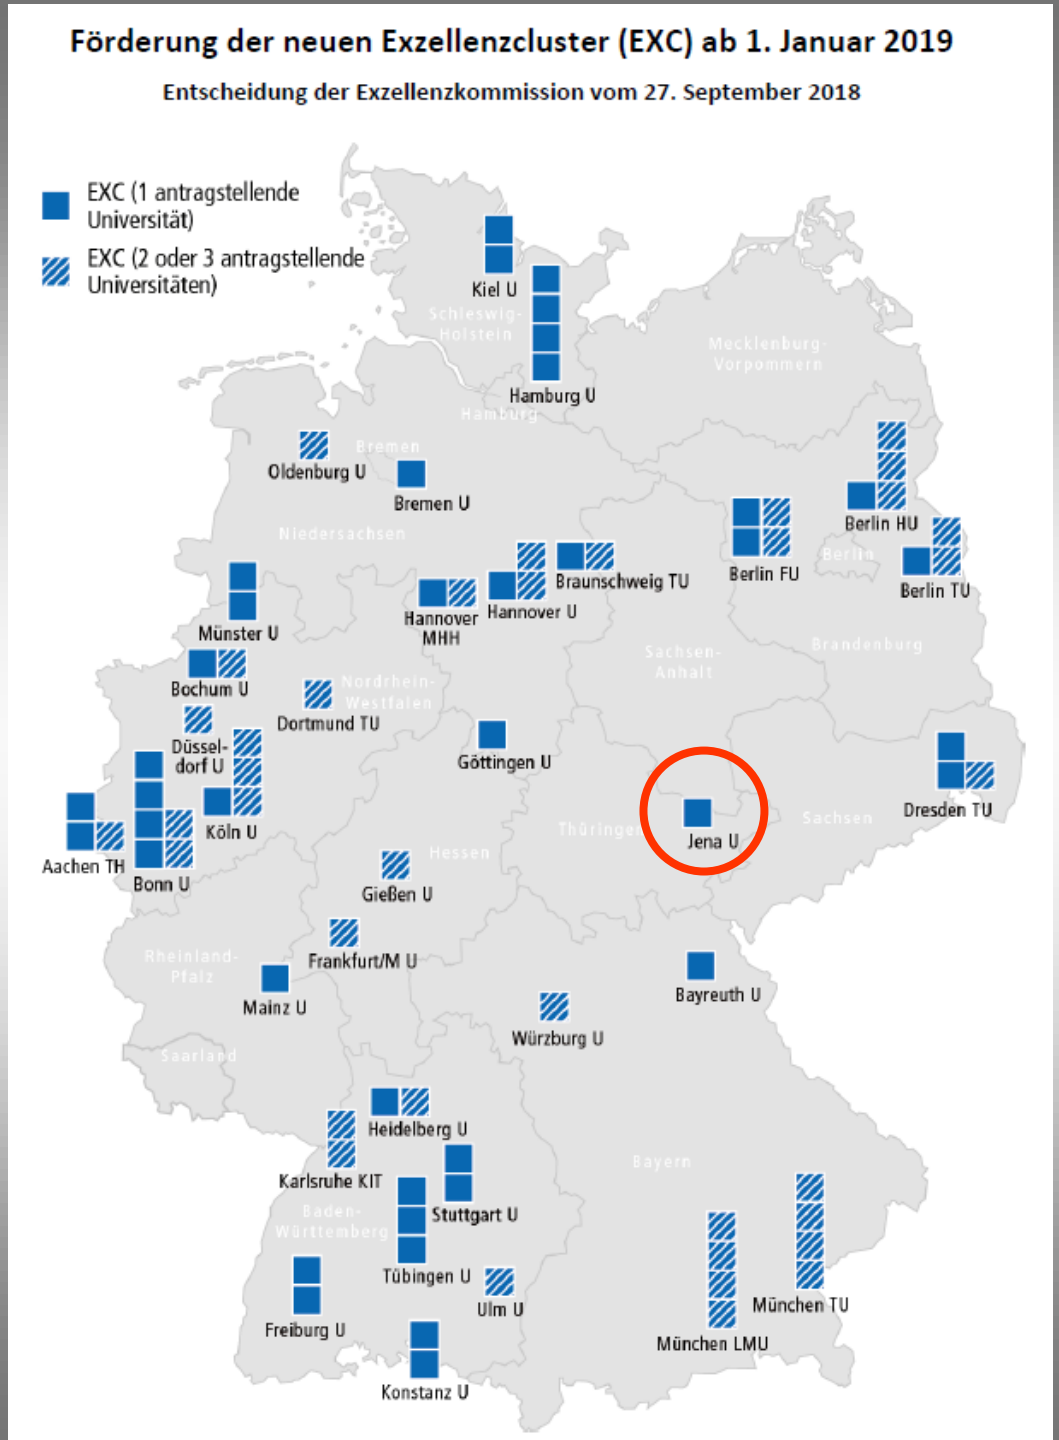

Woher kommt Exzellenz ?

- (High-impact-)Publikationen
- Wissenschaftspreise
- Drittmitteleinwerbungen
  - SFBs, Graduiertenschulen …
- Zukunftsentwürfe

- Im internationalen Kontext weltweit sichtbar sein (visibility)

Ein Beispiel für den Nachweis wissenschaftlicher Exzellenz

- Semantik
  - Bedeutung von Sprache
- Semantische Textanalytik
  - Inhaltliche Analyse von Texten
- Informationsbeschaffung für Biologen und Mediziner
  - Medline/PubMed: mehr als 27M Dokumente
- „Weltmeisterschaft“ für semantische Textanalytik
  - Wo ist Jena (JULIE Lab) ?

<Semantische Textanalytik>

- **Natürlichsprachliche Semantik**
  - **Lexikalische Semantik, Satzsemantik**
- **Term-Semantik**
  - **Termvarianten: Synonyme, Akronyme, Abkürzungen**
- **Typen-Semantik**
  - **Generalisierung auf Klassen**
- **Propositionale Semantik**
  - **Prädikationen : $p(a_1, \ldots, a_n)$, a_i kann Term sein, aber auch eine Prädikation**

Propositionale Semantik

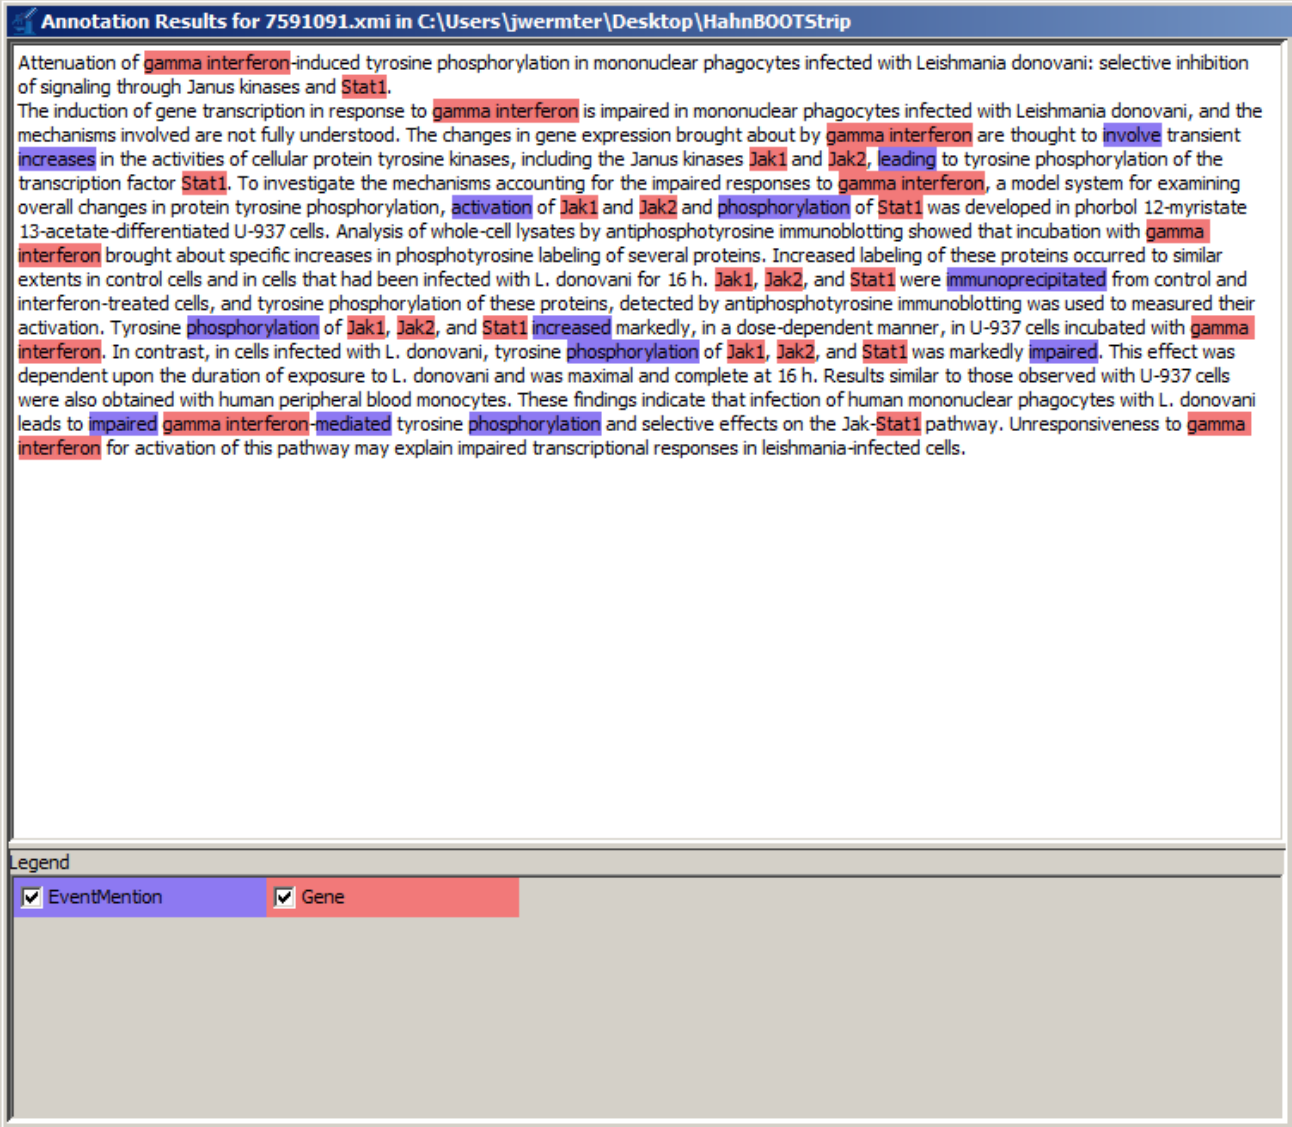

Propositionale Semantik

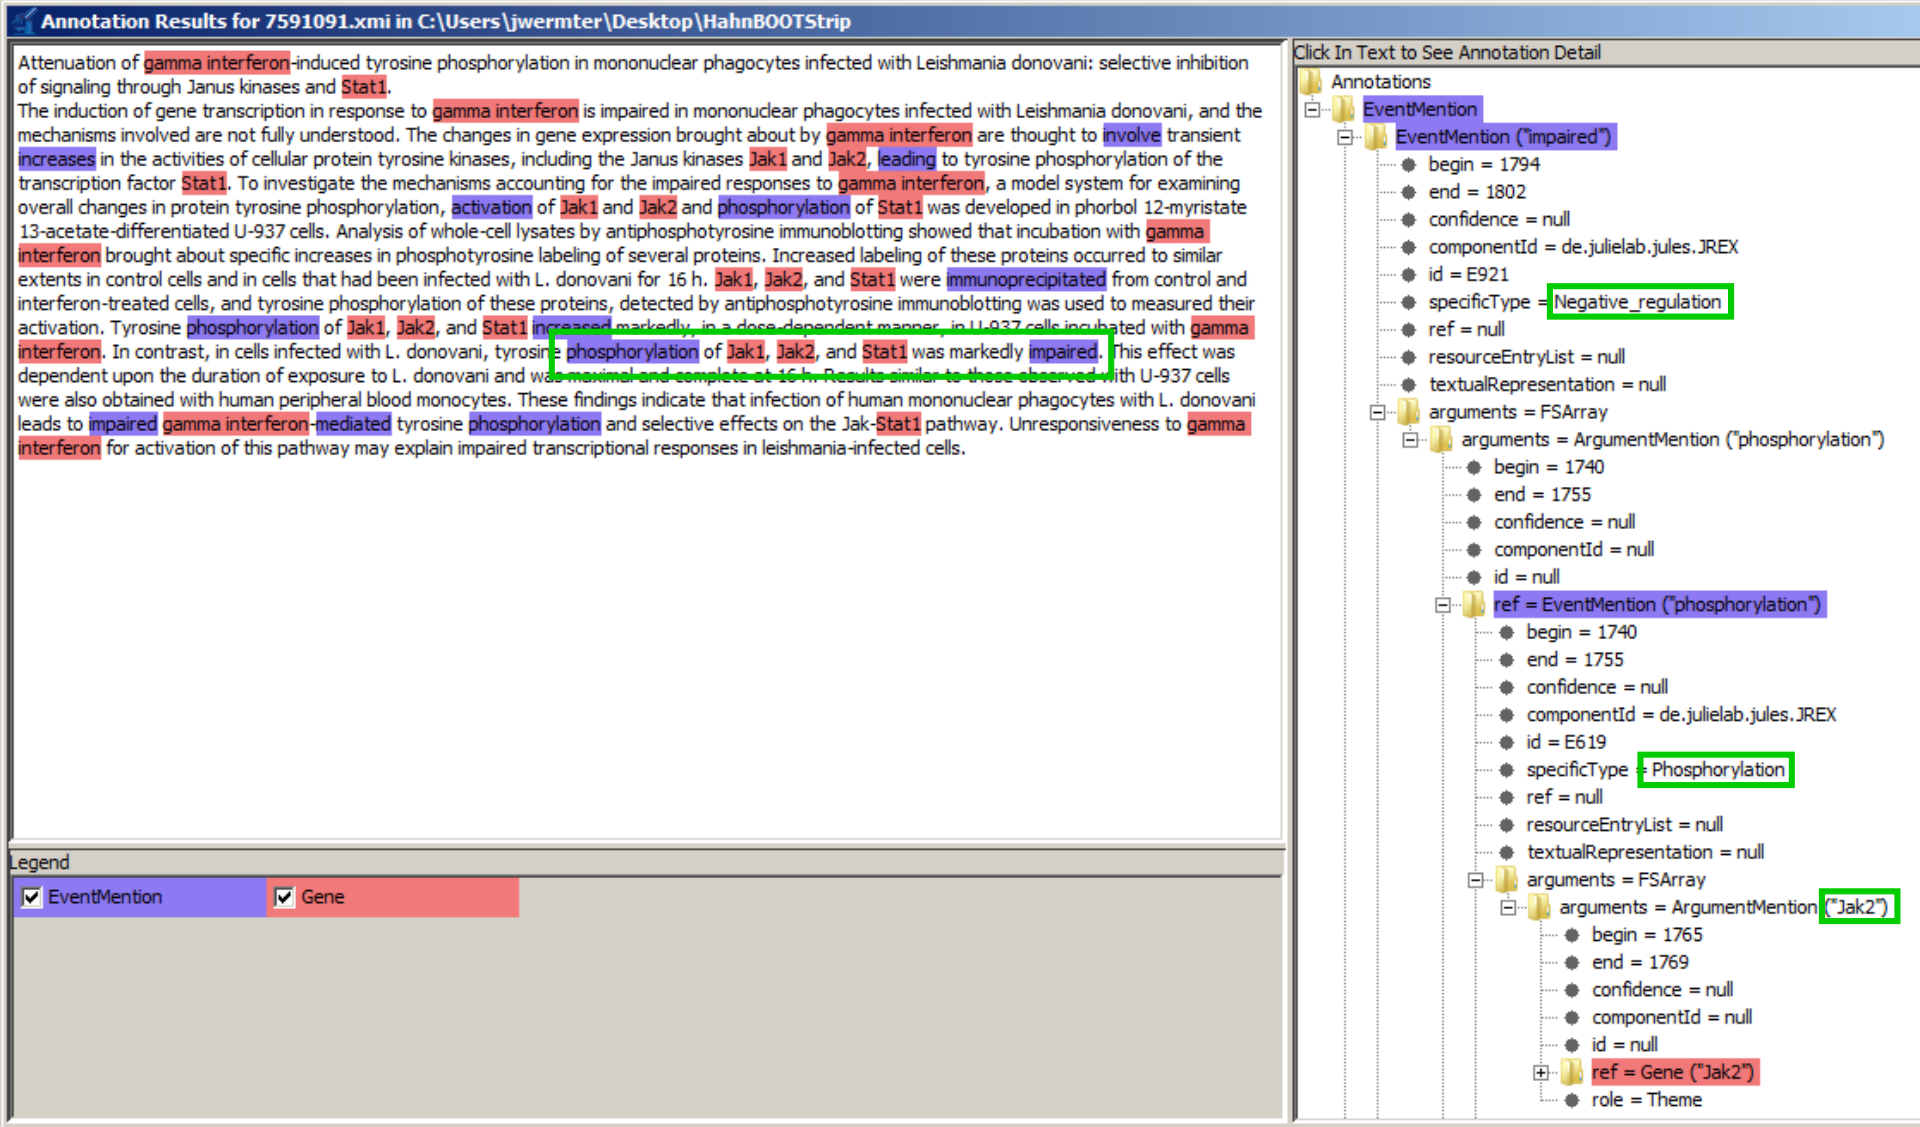

Challenge Competitions

- ParsEval, SemEval, RTE, …
- MUC, ACE, TAC, SUMMAC
- BioCreative I, II. II.5, III, IV, LLL, NLPBA
- TREC (Genomics), CLEF eHealth, i2b2
- BioNLP'09 Shared Task on Event Extraction
  - `http://www-tsujii.is.s.u-tokyo.ac.jp/GENIA/SharedTask/`
- CALBC, MANTRA

http://www.duckipedia.de/images/3/39/Tick,_Trick_und_Track_.jpg

Challenge Competition (1/3)

1. (vertrauenswürdiger, fairer, objektiver) Ausrichter konstituiert sich
   - Thematik des Challenge festlegen
   - Textauswahl, Formate etc.
   - Wettbewerbssoftware bereitstellen
2. Anfertigung des Goldstandards (*ground truth*)
   - Aufspaltung in
     - Training-Set (70/90)
     - Test-Set (30/10)

Challenge Competition (2/3)

3. **Freigabe des Training-Set (Dauer: 3-6 W)**
   - Teilnehmer trainieren ihr System am Training-Set
   - Vergleich eigener Ergebnisse gegen Goldstandard
   - Teilnehmer fixiert am Ende der Trainingsphase *n* optimale Systemzustände (*frozen system*)
4. **Freigabe des Test-Set (Dauer: 2-3 T)**
   - Frozen system operiert auf Test-Set

Challenge Competition (3/3)

5. Abgabe der Ergebnisse beim Ausrichter
6. Auswertung der Ergebnisse des Test-Set-Laufs beim Ausrichter
   - Vergleich eigener Ergebnisse gegen Goldstandard
   - Standardisierte Metriken für Qualitätsmessung (precision, recall, F-score)
7. Vergleich und Ranking aller Teilnehmer durch Ausrichter
   - anonym (bei Bedarf)

And the winner is …

Final Evaluation Results on **ALL-TOTAL** events by **Approximate Span & Recursive** Matching

Team	gold (match)	answer (match)	recall	precision	fscore
U Turku (FIN)	3182 (1487)	2541 (1486)	46.73	58.48	51.95
FSU Jena/JULIELab (GER)	3182 (1458)	3068 (1458)	45.82	47.52	46.66
Concordia U/CLaC (CAN)	3182 (1113)	1807 (1113)	34.98	61.59	44.62
U Tokyo+DBCLS (JAP)	3182 (1174)	2110 (1173)	36.90	55.59	44.35
Ghent U/VIB(BEL)	3182 (1063)	2062 (1063)	33.41	51.55	40.54
U Tokyo/Tsujii Lab (JAP)	3182 (895)	1671 (895)	28.13	53.56	36.88
U New South Wales (AUS)	3182 (898)	1957 (896)	28.22	45.78	34.92
U Zurich (SWI)	3182 (883)	1895 (883)	27.75	46.60	34.78
Arizona SU+HUB+BU(USA)	3182 (688)	1106 (688)	21.62	62.21	32.09
U Cambridge (UK)	3182 (672)	1181 (672)	21.12	56.90	30.80
U Antwerp/CNTSLTG (BEL)	3182 (716)	1501 (716)	22.50	47.70	30.58
U Manchester (UK)	3182 (702)	1444 (702)	22.06	48.61	30.35
SCAI Fraunhofer Inst (GER)	3182 (826)	2278 (826)	25.96	36.26	30.26
UAveiro (POR)	3182 (666)	1351 (666)	20.93	49.30	29.38
Team 24 (???)	3182 (722)	1778 (721)	22.69	40.55	29.10
U Szeged (HUN)	3182 (685)	1852 (685)	21.53	36.99	27.21
NICTA/U Melbourne (AUS)	3182 (555)	1388 (555)	17.44	39.99	24.29
CNB Madrid (ESP)	3182 (911)	4362 (911)	28.63	20.88	24.15
U Colorado/BTMG (USA)	3182 (428)	596 (428)	13.45	71.81	22.66
Arizona SU/CIPS (USA)	3182 (725)	3809 (725)	22.78	19.03	20.74
U Michigan (USA)	3182 (968)	6859 (968)	30.42	14.11	19.28
Sirma/Ontotext (BUL)	3182 (358)	538 (358)	11.25	66.54	19.25
Team 09 (???)	3182 (372)	1184 (372)	11.69	31.42	17.04
KoreaU (KOR)	3182 (299)	485 (299)	9.40	61.65	16.31

Post-competition Results I

Final Evaluation Results on **ALL-TOTAL** events by **Approximate Span & Recursive** Matching

Team	gold (match)	answer (match)	recall	precision	fscore
U Turku (FIN)	3182 (1487)	2541 (1486)	46.73	58.48	51.95
FSU Jena/JULIELab (GER)	3182 (1458)	3068 (1458)	45.82	47.52	46.66

Evaluation Results on **ALL-TOTAL** events by **Approximate Span & Recursive** Matching
after System Overhaul and further Tuning

Team	gold (match)	answer (match)	recall	precision	fscore
U Turku (FIN)					52.86
FSU Jena/JULIELab (GER)					51.10

In:
Computational Intelligence
Vol. 27, 2011, No.4, pp.610-44.

Post-Competition Results II

Participant	Rank in F1 score	Total			Localization	Binding	Gene expression	Transcription	Protein catabolism	Phosphorylation	Regulation	Positive Regulation	Negative Regulation	BioNLP '09 ST Total Evaluation
	#	F1	PR	RC	F1	F1	F1	F1	F1	F1	F1	F1	F1	F1
JULIE Lab JReX [1]	1	51.09	57.69	45.85	61.60	49.24	72.48	42.99	80.00	81.99	31.20	40.39	38.47	46.66
UTurku [2]	2	49.91	56.32	44.81	55.85	45.43	71.67	50.21	50.00	79.70	33.97	38.66	36.28	51.95
EventMine [3]	3	48.20	64.00	38.65	63.20	39.86	72.63	50.00	60.87	81.29	28.77	28.25	32.62	36.88
BExtract [4]	4	44.48	61.56	34.82	51.45	26.97	65.14	24.71	60.00	80.69	32.21	35.83	33.27	44.62
VIBGhent [7]	5	42.44	59.05	33.12	51.79	34.42	69.57	57.14	68.97	76.23	19.39	23.34	26.67	40.54
TheBeast [8]	6	37.19	48.15	30.30	48.98	34.50	59.28	17.48	72.00	72.79	29.96	29.57	27.32	44.35
UMich [9]	7	36.34	35.57	37.15	53.47	31.75	66.00	30.06	58.06	77.15	14.29	21.50	26.61	19.28
Moara [6, 10]	8	29.50	31.99	27.31	44.19	28.36	58.79	26.40	50.00	52.88	10.83	14.68	13.16	24.15
CCP-BTMG [13]	9	22.03	70.03	13.07	17.80	20.92	51.07	22.93	40.00	33.33	5.79	6.69	4.01	22.66

In:
BMC Bioinformatics
Vol. 12, 2011, No.481

… so erarbeitet man sich Forschungsexzellenz !

Merkmale von Challenge Competitions

- Internationaler Ideen-Wettbewerb
- Intersubjektive Bewertung
- Saubere Vergleichsmaßstäbe: Metriken
- Experimente
- Trennung Experimentator/Entwickler
- „sportlicher“ Aspekt
- Offenlegung der Methoden
  - Treiber für Methodenfortschritt
  - Latente Gefahr des Methodenkonservativismus‘
- Exemplarischer Fall empirischer Wissenschaft: Rationalität

</Exkurs>

Computerlinguistik I

- Linguistik: Gegenstandsbereich sind (überwiegend) natürliche Sprachen
  - Deutsch, Englisch, Französisch, ...
- Beispiele für formale Sprachen
  - $L = \{a^n b^n, n \in \mathbb{N}\}$

    $= \{ab, aabb, aaabbb, aaaabbbb, \ldots\}$
  - jede Programmiersprache, Auszeichnungssprache
    - JAVA, C++, ..., XML, HTML, ...
  - jede Logik
    - Aussagenlogik, Prädikatenlogik, Typenlogik, ...
  - Differentialgleichungen, Integrale, Vektoren, ...

Formale Sprachen

- Konstruiert
  - Rein definitorischer (konstruktiver) Ansatz
- Möglichst non-ambig
  - Eindeutige syntaktische wie semantische Strukturen
- Statisch
  - zum Definitionszeitpunkt komplett fixiert
  - Endliches Vokabular
- „Einfache“ Beschreibung
  - Wenige Regeln, wenige Axiome
  - meist wenige Elemente umfassendes Vokabular („Lexikon“)
  - Wenige Schichten: Syntax, Semantik; keine Pragmatik
- striktes Wohlgeformtheitskriterium
  - Außer-definitorische Strukturen sind nicht wohlgeformt
  - … und damit nicht prozessierbar

Natürliche Sprachen

- Konventionalisiert durch ‚sozialen Vertrag' einer Sprechergemeinschaft
  - Ausübung des Sprechens unterliegt sozialen Normen, Gewohnheiten und (impliziten) Übereinkünften (Regelkonformität)
- Hochgradig ambig
  - Mehrdeutige lexikalische, syntaktische, semantische, pragmatische Strukturen
- Dynamisch
  - Sprache verändert sich im Laufe der Zeit (Lexikon, Syntax)
  - Unendliches Vokabular (Komposition, Derivation)
- Komplexe Beschreibungen
  - Viele Regeln, viele Axiome
  - Sehr großes Vokabular („Lexikon")
  - Starke Schichtung von Beschreibungsebenen
- laxe Wohlgeformtheitskriterien
  - Außer-definitorische Strukturen sind zwar nicht wohlgeformt, werden aber (bis zu einem gewissen Grad) verstanden