



Optimierung und Sicherung der Datenqualität von STOFF-IDENT



V. Gronau¹, Wielenbach/D., M. Luthardt³, Weihenstephan/D., T. Placht³, Weihenstephan/D., A. Gilg³, Weihenstephan/D., F. Leßke³, Weihenstephan/D., M. Sengl², Augsburg/D., M. Letzel¹, Wielenbach/D.

¹Bayerisches Landesamt für Umwelt, Demollstraße 31, 82407 Wielenbach

²Bayerisches Landesamt für Umwelt, Bürgermeister-Ulrich-Str. 160, 86179 Augsburg

³Hochschule Weihenstephan-Triesdorf, Vöttinger Str. 27, 85354 Freising

Bayerisches Landesamt für Umwelt, Demollstraße 31, 82407 Wielenbach, veronika.gronau@lfu.bayern.de

STOFF-IDENT- Datenbank

- Hilfsmittel zur Identifizierung bislang unbekannter gewässerrelevanter Stoffe mithilfe der Non- und Suspected-Target Analytik
- Integration der Stoffdaten aus Stoffvollzügen (REACH, Biozid-Richtlinie...)
- Einbindung von STOFF-IDENT in die Arbeitsplattform FOR-IDENT zur Verknüpfung mit anderen Recherche-Tools (MetFrag, MassBank etc.)

Datenqualität und Datenumfang

- Integration weiterer gewässerrelevanter Stoffe in die Datenbank sowie die Aktualisierung bereits vorhandener Stoffgruppen (neu registrierte Substanzen aus Stoffvollzügen)
- Kontinuierliche Prüfung und Optimierung der Datenqualität
- Fehlersuche und -korrektur (seit Projektbeginn Umwandlung von >1.500 Fehlern und falschen Zusatzinformationen in Datensätzen)
- Konzept eines effizienten Datenmanagementsystems

Datenumfang *



* Die Gesamtliste aller STOFF-IDENT-Einträge ist auf der NORMAN-Homepage zum Download abrufbar: <http://www.norman-network.com/?q=node/236>

** Aufgrund von Überschneidungen liegt der Datenbestand trotz 16.459 eingeleiteter Substanzen aktuell bei 9.500 gewässerrelevanten Stoffen

Prüfregeln zur Sicherung der Datenqualität bei neuen Daten

- Substanz muss CAS-Nummer oder SMILES-Code haben
- Richtigkeit der CAS-Nummer wird über deren Prüfziffer geprüft
- SMILES und Summenformel dürfen keinen Punkt und kein * enthalten
- + im SMILES führt zu gesonderter Überprüfung der Substanzen
- $-20 < \log P < 20$

Automatisierte Fehlererkennung im SI-Crawler, dem Daten-Einlesetool

Completen...	Suspicious	Name	Source	CAS	Source	SMILES
●	●	Acidover	UBA	99277-99-3	UBA	Ndnc(O)zncm(COCCO)z[H]l
●	●	ACIPROX	UBA	51037-20-0	Wikipedia	Cd.ncnc(O)O(=O)O(=O)O
●	●	ACITRETIN	UBA	55079-89-9	Wikipedia	COc1cc(C)C=C(C)C1C(C)C(C)C(C)C
●	●	ACLARUBICIN	UBA	57576-44-0	Wikipedia, chem	CC(C)C(=O)C1C(C)C(=O)C(C)C(C)C1
●	●	Acridin	UBA	8063-24-9	chemicalbook.cz	[C]1Nc1ccc2c3ccr1Nc3nc2c1.Cd.c
●	●	ACTINOQUINOL	UBA	15301-40-3	http://www.drug	CCO1ccc(cc2cccnd2S1O)=O1=O
●	●	ADAPALENE	UBA	106685-40-9	Wikipedia, chem	CC(C)C(C)C1C2C3C(C)C(C)C(C)C1(C)2
●	●	Adelovirdipivoxil	UBA	142340-99-6	UBA	CC(C)C(C)C1C2C3C(C)C(C)C(C)C1(C)2
●	●	Ademetionine disulfate tosylate	UBA	97540-22-2	chemicalbook.cz	OS(=O)(=O)C1=O=C(C)C=C1
●	●	ADRENALONE	UBA	99-45-6	chemicalbook.cz	CNCC1=O(C)C(C)C1O1
●	●	Agomelatin	UBA	138112-76-2	UBA	COc1ccc(ccc(CCN(C)C)C)O1
●	●	AMALICINE	UBA	483-04-5	chemicalbook.cz	COc1cc(C)C=C(C)C(C)C1
●	●	AMALINE	UBA	480-12-07	chemicalbook.cz	COc1cc(C)C=C(C)C(C)C1
●	●	ALATROFLOXACIN	UBA	157605-25-9	wikipedia, chemi	CS(O)(=O)O.C(C)C(=O)N(C)C(=O)N(C)C
●	●	ALBENDAZOLE	UBA	54865-21-8	Wikipedia	CCCC1ccc2c(NC1=O)OC(=O)H2c1
●	●	ALCLOMETASONE	UBA	66734-13-2	Wikipedia	CCCC1ccc2c(NC1=O)OC(=O)H2c1
●	●	ALCLOXA	UBA	1337-25-5	chemicalbook.cz	CCCC1ccc2c(NC1=O)OC(=O)H2c1

Kategorisierung und Taggen

- Jede in der Datenbank enthaltene Substanz ist einer oder mehreren Kategorien zugeteilt (REACH, Pharmaceuticals, Biocides, PSM, TP's)
- Taggen bedeutet, dass eine Substanz mehreren Ursprungslisten zugewiesen werden kann, z.B. zur Spezialsuche in einzelnen Listen: REACH, einzelne Laborlisten, Liste positiv geladener Substanzen, ...

Bsp.: Triphenylphosphonium mit M suchen



Suche über M [+H]

Kein Ergebnis bei Suche im positiven Ionenmodus, da Masse um +H falsch liegt

Suche über M [±0]

Suche erfolgreich im Ionenmodus [±0], Substanz wurde gefunden, da positive Grundladung

neu Automatisierte Gruppensuche aller Substanzen mit positiver Grundladung über M [±0] möglich

Fazit und Ausblick

- Stetig steigende Nutzerzahlen (dadurch weitere Fehlerelimination)
- Verstärkter Fokus auf Transformationsprodukte
- Optimierung der automatischen Fehlererkennung
- Kontinuierliche Erhöhung des Datenbestandes durch Integration weiterer Laborlisten (national und international)

