
Semi-automatisierte Plausibilitätsprüfung in Citizen Science gestützten Naturbeobachtungen

Clemens JACOBS¹ und Bernd RESCH²

Universität Heidelberg, Geographisches Institut, Abteilung für Geoinformatik ·
¹clemens.jacobs@geog.uni-heidelberg.de · ²bernd.resch@geog.uni-heidelberg.de

Zusammenfassung

Schon seit einigen Jahren können interessierte Laien Beobachtungen von Tier- und Pflanzenarten in entsprechenden Web-basierte Portalen sammeln. Der Artenfinder Rheinland-Pfalz (www.artenfinder.rlp.de) ist ein solches Portal, das darüber hinaus zum Ziel hat, die gesammelten Meldungen in den amtlichen Datenbestand des Landes Rheinland-Pfalz zu überführen. Bisher wird die Qualitätssicherung der Daten allerdings ausschließlich manuell von Experten durchgeführt, was durch die stark steigende Anzahl von Laienbeobachtungen zunehmend zu einem Kapazitätsproblem führt. Ziel des in diesem Beitrag vorgestellten Projektes ist es, semi-automatisierte Plausibilitätskontrollen bereit zu stellen, die die prüfenden Experten unterstützen. Durch Auswertung der bereits vorhandenen Meldungen werden regelbasierte Indikatoren für die Plausibilität der zu prüfenden Fundmeldungen gewonnen. Dabei werden verschiedene Aspekte betrachtet, wie beispielsweise die räumliche Lage und die Jahreszeit, aber auch die Fähigkeiten des jeweiligen Melders. In einem geplanten Evaluierungsschritt werden die Werkzeuge auf ihre Wirksamkeit geprüft und ggf. angepasst und verbessert. Zukünftig wird auch die Integration von Complex Event Processing Mechanismen erforscht, um der Vision stärker automatisierter Plausibilitätskontrollen einen Schritt näher zu kommen.

1 Hintergrund

Das Sammeln naturschutzrelevanter Daten, insbesondere Beobachtungen von Tier- und Pflanzenarten, durch interessierte Laien hat in den letzten Jahren einen großen Aufschwung erlebt. Eine besondere Rolle spielen hierbei Web-basierte Portale, die die Infrastruktur zur Dateneingabe und -speicherung bereitstellen (SULLIVAN et al. 2009). Freiwillige können hier ihre Beobachtungen sammeln und mit anderen teilen. Ziel ist es häufig, interessierte Laien für Naturschutzthemen zu begeistern und sie für die aktive Mitarbeit zu gewinnen (CONRAD & HILCHEY 2011).

1.1 Projekthintergrund

Das Projekt „Artenfinder Rheinland-Pfalz“ (www.artenfinder.rlp.de), eine gemeinsame Initiative des Landes Rheinland-Pfalz und der Naturschutzverbände POLLICHIA, NABU und BUND, geht einen Schritt weiter. Sein Ziel ist der Transfer von gesetzlich geschützten

Arten, die durch freiwillig tätige Laien gesammelt werden, in den amtlichen Datenbestand des Landes Rheinland-Pfalz. Daraus resultiert ein hoher Qualitätsanspruch an die Korrektheit der Daten. Daher werden sämtliche zur Übernahme in den amtlichen Datenbestand des Landes vorgesehenen Meldungen durch anerkannte Experten geprüft und anschließend freigegeben oder abgelehnt (JACOBS 2012). Die Experten werden hauptsächlich aus den Mitarbeitern und Mitgliedern der Naturschutzverbände POLLICHIA, NABU und BUND rekrutiert. Sie werden von der eigens zu diesem Zweck eingerichteten KoNat (Koordinierungsstelle der kooperierenden Naturschutzverbände – Naturschutzdaten) koordiniert. Eine enge Kooperation besteht mit dem Portal www.naturgucker.de, aus dem regelmäßig große Mengen an Meldungen übernommen werden (nachdem sie ebenfalls durch Experten geprüft wurden). Umgekehrt können Meldungen aus dem Artenfinder auf einfache Art und Weise in www.naturgucker.de übertragen werden.

Das System der Qualitätssicherung durch koordinierte Experten hat sich bewährt, stößt aber angesichts einer rasch steigenden Zahl von Meldungen (im Frühjahr 2013 wurde die Marke von 100.000 Meldungen überschritten) an seine Grenzen. In dieser Situation entstand der Gedanke, den Qualitätssicherungsprozess durch ein Software-Werkzeug zu unterstützen. In einem Projekt, das im Rahmen des Bundesprogramms Biologische Vielfalt vom deutschen Bundesamt für Naturschutz (BfN) mit Mitteln des Bundesministeriums für Umwelt, Naturschutz und Reaktorsicherheit und der Stiftung Natur und Umwelt Rheinland-Pfalz gefördert wird, werden nun Plausibilisierungswerkzeuge implementiert und erprobt, die die Arbeit der Experten unterstützen sollen. Träger des Projekts ist die naturforschende Vereinigung POLLICHIA. Das geographische Institut der Universität Heidelberg (Lehrstuhl für Geoinformatik) wurde mit der wissenschaftlichen Begleitung des Projektes beauftragt. Den Auftrag für die Entwicklung der Software erhielt die Firma Leiner & Wolff (Heidelberg).

1.2 Qualitätssicherung durch Plausibilitätskontrollen

Plausibilitätskontrollen sind ein Instrument zur Sicherung der Qualität von Daten, das in verschiedenen Domänen eingesetzt wird. Die Plausibilitätsprüfung basiert zumeist auf dem Abgleich der zu prüfenden Daten mit zuvor aufgestellten Regeln, mit dem Ziel, unplausible Daten zu markieren und einer Prüfung (z.B. durch geeignete Experten) zuzuführen, als deren Ergebnis sie schließlich angenommen, zurückgewiesen oder korrigiert werden. Die Anwendung definierter Plausibilitätskriterien (in Form von Regeln) und die Dokumentation der Ergebnisse der Plausibilitätsprüfung führen dabei auch zu einer Objektivierung des Plausibilisierungsprozesses, da die Grundlagen für die Annahme oder Zurückweisung von Daten besser nachvollziehbar sind (SCHERRER et al. 2011). Je nach Domäne werden bei der Plausibilitätskontrolle sehr unterschiedliche Kriterien angewendet.

Ein Beispiel für ein Erhebungssystem für Biodiversitätsdaten durch Laien, in dem die Plausibilität der Eingaben geprüft wird, ist das US-amerikanische Portal eBird (www.ebird.org). Es sammelt Beobachtungsdaten von Vögeln. Prüfkriterien sind die gemeldete Anzahl einer Art sowie auch das jahreszeitlich-regionale Vorkommen von Arten (SULLIVAN et al. 2009). Unplausible Meldungen werden markiert und von Experten geprüft.

Im Projekt OpenStreetMap (OSM - www.openstreetmap.org), in dem online durch engagierte Freiwillige eine freie Weltkarte erzeugt wird, werden Plausibilitätskontrollen eingesetzt, um die Qualität der erzeugten Geodaten zu sichern. Für OSM-Daten gibt es eine Reihe von Software-Tools, die die Qualitätsprüfung unterstützen. Die meisten dieser Werkzeug-

ge detektieren mithilfe von Regeln bestimmte Inkonsistenzen in den Daten (beispielsweise nicht geschlossene Flächen, nicht angeschlossene Linienenden) oder fehlende Angaben (SCHÖN et al. 2012). Ein weiteres Beispiel für Community-basierte Informationsportale ist Wikipedia. Qualitätssicherung wird hier vordergründig über „Wisdom of the Crowd“, also die kollektive Intelligenz der Beitragenden, und über einfache Regeln wie die Anzahl der Beitragenden oder die Anzahl der Änderungen realisiert. Anderka et al. (2011) schlagen erstmals einen Mechanismus zur automatisierten Qualitätskontrolle vor, der Fehler in Wikipedia-Artikeln auf Basis von probabilistischer Fehlererkennung durch den Vergleich mit vermeintlich fehlerfreien Artikeln identifizieren soll.

2 Softwaregestützte Plausibilitätstests für Artenmeldungsdaten

Das hier vorgestellte Projekt hat zum Ziel, den Plausibilisierungsprozess von Artfunddaten, die von interessierten Laien an entsprechende Web-Portale gemeldet werden, durch automatisierte Tests zu unterstützen. Zu diesem Zweck wird eine Web-basierte Software entwickelt, die entsprechende Werkzeuge enthält. Die Werkzeuge schätzen die Plausibilität neu hinzukommender Meldungen ab, indem sie diese mit Informationen aus dem vorhandenen Datenbestand des Meldeportals abgleichen. Die Ergebnisse der Prüfungen werden zu einer Gesamteinschätzung der Plausibilität der zu prüfenden Meldung zusammengefasst. Der prüfende Experte erhält außerdem eine Darstellung der Einzelergebnisse der Prüfschritte. Dies wird pilothaft mithilfe des Artenfinders Rheinland-Pfalz implementiert und erprobt.

Nachfolgend werden die methodischen Ansätze vorgestellt, die wir dabei verfolgen. Sie werden derzeit in konkrete Plausibilisierungswerkzeuge umgesetzt und in eine Web-basierte Software eingebettet. Zugleich erfolgt auch eine Optimierung des Workflows bei der Beurteilung der Meldungen durch eine Zusammenfassung aller vom prüfenden Experten benötigten Informationen und Funktionen in einer leicht zu bedienenden Oberfläche. Die Software ist so konzipiert, dass weitere Plausibilisierungsmethoden modular hinzugefügt werden können. Nach ihrer Fertigstellung steht die im Rahmen des Projekts entwickelte Software auch anderen Meldesystemen zur Nutzung offen.

2.1 Expertise des Melders

Ein wesentliches Kriterium zur Abschätzung der Zuverlässigkeit einer Meldung ist die Zuverlässigkeit ihrer Quelle. In unserem Fall stellt sich die Frage, wie hoch die Sicherheit eines Melders bei der Bestimmung der von ihm gemeldeten Arten eingeschätzt werden kann. Melder entwickeln mit einer steigenden Zahl von Meldungen in der Regel rasch eine größere Sicherheit bei der Bestimmung. Diese Fähigkeit ist allerdings artgruppen- oder sogar artspezifisch. Außerdem sind Arten (auch aus derselben Artengruppe) unterschiedlich schwierig zu bestimmen bzw. leicht zu verwechseln. Daher erfolgt die Ableitung des Expertengrades eines Melders durch Analyse seiner bisherigen Meldetätigkeit aus der Zahl der akzeptierten und abgelehnten Meldungen in der betreffenden Artengruppe und unter Berücksichtigung der Bestimmungsschwierigkeit der betreffenden Arten.

2.2 Zeitpunkt der Meldung im Jahreslauf

Viele Arten weisen hinsichtlich ihres jahreszeitlichen Vorkommens in einer bestimmten Region eine charakteristische Häufigkeitsverteilung auf. Aus dieser Tatsache lässt sich ein

ATKIS (Amtliches Topografisch-Kartografisches Informationssystem) basiert. Das Werkzeug wird allerdings so gestaltet, dass der Betreiber der Plausibilisierungssoftware hierfür auch andere, selbst gewählte Datengrundlagen verwenden kann.

3 Erprobung und Evaluation

Das beschriebene Projekt gibt Gelegenheit, die Möglichkeiten und Grenzen (semi-) automatisierter Plausibilitätstests für von Freiwilligen erhobene Biodiversitätsdaten auszuloten und (mit dem Artenfinder Rheinland-Pfalz) an einem produktiv arbeitenden Meldesystem zu erproben. Diese Erprobung beginnt voraussichtlich im Sommer 2013. Dabei wird evaluiert, ob die angewendeten Prüfmethode fehlerhafte Meldungen zuverlässig erkennen. Die Evaluierung wird außerdem zeigen, wo die Grenzen der hier vorgestellten Prüfmethode liegen, insbesondere hinsichtlich ihrer Anwendbarkeit auf die einzelnen Arten bzw. Artengruppen (diese haben sehr unterschiedliche Eigenschaften bzw. Ausbreitung, Mobilität, Wanderungsverhalten usw.) sowie regionale Unterschiede in den auszuwertenden Meldungsdaten (v.a. bezüglich der räumlichen Dichte der vorhandenen Meldungen). Außerdem wird zu prüfen sein, ob die Software die Arbeit der prüfenden Experten wesentlich erleichtert und beschleunigt.

4 Ausblick

Die stark steigende Anzahl von Naturbeobachtungen durch „Citizen Scientists“ – also Laien mit grundlegendem Wissen in einem speziellen Gebiet wie Beobachtung von Tieren und Pflanzen – bedingt die Entwicklung von neuartigen semi-automatisierten Mechanismen für Qualitätskontrolle. Hierfür sind besonders Complex Event Processing (CEP) Methoden (BASS 2013) geeignet, die zur regelbasierten Mustererkennung in Datensätzen dienen.

Da CEP-Methoden traditionell in aräumlichen Anwendungen (Vorhersage von Börsenkursen, Antizipation von Marktentwicklungen, etc.) zum Einsatz gekommen sind, stellt speziell die Integration der räumlichen Dimension in bestehende CEP-Mechanismen eine entscheidende Herausforderung dar. CEP bietet hier die Möglichkeit, die in Kapitel 2 genannten Parameter zur Plausibilitätskontrolle abzubilden und in Systeme zur Eventerkennung (z.B. räumliche Plausibilität, Artähnlichkeit/Verwechslungsgefahr, räumliche Dichte von Meldungen einer Art, etc.) umzusetzen.

Hierfür gilt es allerdings noch, zwei grundlegende Forschungsfragestellungen zu beantworten: 1.) die Optimierung und Standardisierung der Regelwerkstruktur zur Abbildung und Speicherung der Regeln; und 2.) die Objektivierung der Regeln an sich – also die regelbasierte Analyse ohne manuelle Intervention (soweit möglich) – um sie für ein CEP-System nutzbar zu machen.

Speziell die Erstellung der Regelwerke stellt eine entscheidende Herausforderung dar, weil eine konsistente Formalisierung der einzelnen Regeln und deren Zusammenhang oft schwer objektivierbar sind. So können etwa Extremwerte (z.B. Beobachtung einer Spezies außerhalb ihres bisherigen Verbreitungsgebietes) einerseits als „Messfehler“ angesehen werden (WIESER 2013), andererseits besteht aber die Möglichkeit, dass diese Extremwerte außer-

gewöhnliche aber valide Beobachtungen darstellen, die potenziell ein Indikator für die Ausbreitung einer Spezies über ihr bisheriges Verbreitungsgebiet hinaus sein kann.

Im Bezug auf die Abbildung der Regelwerke gibt es derzeit verschiedene Ansätze, die von einfachen Textdateien über XML-basierte Strukturen bis hin zu datenbankbasierten Methoden reichen. Ein großes Manko besteht derzeit noch darin, dass die einzelnen Ansätze nicht oder nur mangelhaft miteinander kombinierbar sind. Deshalb stellt die XML-basierte Event Pattern Markup Language (EML) (EVERDING & ECHTERHOFF 2008) einen vielversprechenden Standardisierungsversuch für eine einheitliche Regelsprache dar.

Trotz dieser offenen Forschungsfragen kann zusammenfassend festgehalten werden, dass regelbasierte CEP-Ansätze für die Plausibilitätskontrolle von Citizen Science Daten sehr gut geeignet sind. Dies gründet vor allem auf der Fähigkeit, „komplexe“ Events zu erkennen, die sich aus mehreren Dimensionen (räumlich, zeitlich, kausal) zusammensetzen. Damit rückt auch die Vision stärker automatisierter Plausibilitätskontrollen in greifbare Nähe.

Literatur

- ANDERKA, M., STEIN, B. UND LIPKA, N. (2011): Towards automatic quality assurance in Wikipedia. 20th International Conference on World Wide Web (WWW 2011), Hyderabad, India, 5-6.
- BASS, T. (2013): What is Complex Event Processing?. <http://www.thecepblog.com/what-is-complex-event-processing>, 2013. (11. Januar 2013)
- CONRAD, C. C. UND HILCHEY, K. G. (2011): A review of citizen science and community-based environmental monitoring: issues and opportunities. In: *Environmental Monitoring and Assessment* 176, 273–291.
- EVERDING, T. UND ECHTERHOFF, J. (2008): Event Pattern Markup Language (EML). OGC Discussion Paper 08-132, Version 0.3.0, 05. November 2008.
- JACOBS, C. (2012): Anderthalb Jahre Artenfinder Rheinland-Pfalz – eine Zwischenbilanz. In: *Mitteilungen der Pollichia*, Band 97 Supplement, 51-53.
- SCHERRER, S. C., FREI, C., CROCI-MASPOLI, M., VAN GEIJTENBEEK, D., HOTZ, C. UND APPENZELLER, C. (2011): Operational quality control of daily precipitation using spatio-climatological plausibility testing. In: *Meteorologische Zeitschrift* 20(4), 397-407.
- SCHÖN, S., GÜNTNER, G., BÖRNER, J.-C., LEITINGER, S., SCHEBELLA, M., STRASSER, A., THALER, S., VIELHABER, M. UND WOLFINGER, A. (2012): Qualitätssicherung bei Annotationen. Soziale und technologische Verfahren in der Medienbranche. Band 5 der Reihe „Linked Media Lab Reports“, herausgegeben von Christoph Bauer, Georg Güntner und Sebastian Schaffert.
- SULLIVAN, B. L., WOOD, C. L., ILIFF, M. J., BONNEY, R. E., FINK, D. UND KELLING, S. (2009): eBird: a citizen-based bird observation network in the biological sciences. In: *Biological Conservation* 142(10), 2282-2292.
- WIESER, A. (2013): Smarte Qualitätssicherung von hydrologischen Messdaten in naher Echtzeit. In: Koch, A., Bill, R. and Donaubaue, A. (Eds.) (2013) *Geoinformationssysteme 2013*, Wichmann Verlag, Berlin, Germany, pp. 279-285.