

# Abbildung kognitiver Fähigkeiten mit Metamodellen

Robin Hirt<sup>1</sup> und Niklas Kühl<sup>2</sup>

**Abstract:** Die Abbildung kognitiver Fähigkeiten in der Informatik erfreut sich im Rahmen von Forschungsbestrebungen in den Bereichen der künstlichen Intelligenz, des maschinellen Lernens und der Mensch-Maschine-Interaktion gesteigerter Popularität. In diesem Beitrag zeigen wir die Möglichkeiten von Metamodellen auf, um kognitive Fähigkeiten mit maschinellem Lernen nachzubilden. Dafür präsentieren wir drei unterschiedliche Klassifizierungsmodelle, die jeweils verschiedene Perspektiven – analog zu menschlichen Sinnen – mit einbeziehen und zeigen, wie sich die Klassifizierung durch eine kognitive Aggregation mit Metamodellen dieser Perspektiven von 70% (reine Textklassifizierung) auf über 80% (Metaklassifizierung) nach  $F_1$ -Metrik verbessert. Metamodelle können daher eine gute Grundlage für das Abbilden kognitiver Fähigkeiten sein und in Zukunft eine vielversprechende Erweiterung von einschichtigen maschinellen Lernverfahren darstellen.

**Keywords:** Kognition, Meta-Lernen, Maschinelles Lernen, Künstliche Intelligenz

## 1 Motivation

Das Nachbilden menschenähnlicher Intelligenz ist ein wichtiges Teilgebiet der Informatik [Ko99]. Nach Modha et al. [Mo11] beschreibt der Term *Cognitive Computing* Verfahren, welche versuchen das menschliche Denken als solches nachzuahmen. Wang [Wa03] definiert *Kognitive Informatik* als multidisziplinären Zweig der Informatik, welcher sich mit den Verarbeitungsmechanismen natürlicher Intelligenz beschäftigt. Unabhängig von der genauen Definition umfasst kognitive Verarbeitung einen breiten Forschungsbereich und reicht von der Nachbildung neuronaler Modelle [Ca13] bis hin zur Erstellung mehrschichtiger Rahmenwerke, welche das Imitieren von menschlichem Lernen ermöglichen sollen [CDI06]. In jedem Fall stellen kognitive Berechnungsverfahren ein vielversprechendes, interdisziplinäres Forschungsfeld dar, welches großes Potenzial besitzt [Yi09]. Alle Ansätze zu kognitiver Verarbeitung sind in der Lage zu lernen, d.h. Informationen in einer Form zu speichern und wieder abzurufen sowie mehrschichtige Zusammenhänge zu erkennen.

Obwohl kognitive Verarbeitung ein vielversprechendes Forschungsfeld ist, sind kognitive Ansätze oft stark auf einen bestimmten Sachverhalt angepasst und schwer transferierbar. Chella et al. [CDI06] beschreiben ein Verfahren, welches es Robotern erlaubt auf Basis von

---

<sup>1</sup> Karlsruhe Institute of Technology (KIT), Karlsruhe Service Research Institute (KSRI), Kaiserstr. 89, 76133 Karlsruhe, Germany, hirt@kit.edu

<sup>2</sup> Karlsruhe Institute of Technology (KIT), Karlsruhe Service Research Institute (KSRI), Kaiserstr. 89, 76133 Karlsruhe, Germany, kuehl@kit.edu

Imitation Bewegungsabläufe zu lernen. Andere Verfahren nutzen kognitive Verarbeitung um im medizinischen Kontext grafische Ergebnisse verschiedener Untersuchungen zu kombinieren [OTO06]. Der Forschungszweig der multimodalen Fusion beschäftigt sich mit mehrschichtigen Auswertung von Multimediadaten.

Hierbei wird beispielsweise das Video getrennt von der Tonspur analysiert und die Analyseergebnisse anschließend gesamtheitlich zu verarbeiten [At10, KBMM08]. In diesem Beitrag stellen wir ein generisches und flexibles kognitives Verfahren vor, welches auf der Basis von Metamodellen, konkret Ensemble-Algorithmen [TD03], *verschiedene* Informationsquellen vereint. Wir testen den Ansatz, um deutsche Twitternutzer hinsichtlich ihres Geschlechts automatisiert zu klassifizieren. Als Basis dienen dafür drei Submodelle, die verschiedene Datenquellen betrachten sowie ein Metamodell, welches diese vereint.

## 2 Methodik

Wir unterscheiden zwischen drei Modellen, welche menschliche "Eindrücke" nachbilden sollen und einem übergeordneten Metamodell, welches diese kombiniert. Dabei bauen wir ein kognitives Metamodell, welches aus verschiedenen, so genannten Submodellen, Resultate kombiniert und eine übergeordnete Einschätzung vollzieht (vgl. Abbildung 1). Grundlage für dieses kognitive Modell muss daher ein Zusammenhang sein, welcher in drei




Abb. 1: Kognitive Fähigkeiten durch die Zusammenführung von Submodellen in einem Metamodell  
verschiedenen Formen einen zusammenhängenden Sachverhalt offenbart. Konkreter benötigen wir drei verschiedenartige Datenpools, welche wir getrennt hinsichtlich einer gemeinsamen Zielvariable mittels Submodellen analysieren. Die Ergebnisse dieser Analysen werden dann durch das Metamodell zusammengefasst und ein übergreifendes Analyseergebnis berechnet. Als Ausgangsproblem unserer Analysen betrachten wir die Prädiktion des

Geschlechts von Twitter Nutzern<sup>3</sup> anhand des öffentlich verfügbaren Nutzerprofils. Hierbei beziehen wir drei Quellen mit ein: Das Nutzerbild, die geschriebenen Tweets und den Namen des Nutzers. Im Folgenden erläutern wir zunächst die einzelnen Submodelle, welche die genannten Quellen analysieren. Daraufhin beschreiben wir den Aufbau des Metamodells, welches die kognitive Funktion nachahmen soll und die Ergebnisse der Submodelle entgegennimmt und automatisiert lernt, in welchen Fällen welches Modell die Vorhersage präzisieren kann. Für die Modellbildung nutzen wir unter anderem Verfahren, welche auf überwachtem maschinellem Lernen basieren. Daher benötigen wir Profile von Twitternutzern, von denen wir das Geschlecht bereits kennen. Um dies zu ermöglichen, sammeln wir zufällig die Profile von deutschsprachigen Twitternutzern und lassen diese von einem unabhängigen Wissenschaftler nach männlich, weiblich oder unbekannt klassifizieren. Profile von Organisationen, Bots oder ähnlichem fallen hierbei in die Kategorie "unbekannt". Insgesamt sammeln wir so 2912 Profile von denen 1342 als "männlich" und 1125 als "weiblich" gekennzeichnet sind.

Um das Geschlecht eines Nutzers anhand der geschriebenen Tweets zu ermitteln, wenden wir überwachtes maschinelles Lernen an, indem wir ein Modell mit klassifizierten Daten trainieren und auf ungesehenen, ebenfalls klassifizierten Daten testen. Hierbei wenden wir ein ähnliches Verfahren wie Burger et al. [Bu11b] an: Zunächst analysieren wir automatisiert die Syntax der Tweets durch Verfahren aus der natürlichen Sprachverarbeitung (z.B. Worthäufigkeiten oder Satzzeichennutzung) und betrachten zusätzlich die Nutzung von Hashtags, Hyperlinks und Smilies. Anschließend wird der bearbeitete Text mittels Stemming [Lo68] weiter transformiert und nachfolgend in eine Vektordarstellung gebracht. Nun wird das maschinelle Modell trainiert und durch eine 10-fache Kreuzvalidierung [St77] validiert. Um einerseits mehr Informationen über den Schreibstil des Nutzers zu erhalten und andererseits die Berechnungsdauer zu minimieren, haben wir mit einem Vortest festgestellt, dass jeweils 50 Tweets des Nutzers pro Klassifizierungsdurchlauf betrachtet werden sollten. Weiterhin bietet die Vorverarbeitung (Kombination von Verfahren) und die Modellbildung (Modelalgorithmus und Parameter) viele Möglichkeiten zur Gestaltung, welche wir mit einer Grid-Search optimieren [HCL08, SLA12]. Wir testen Algorithmen aus drei verschiedenen Gruppen [MST94]: Bayes (Gaussian Naïve Bayes, Bernoulli Naïve Bayes), Support Vector (Linear SVC, SVC) und baum-basiert (Random Forest). Zusätzlich testen wir Ensemble Algorithmen (Adaboost, Bagging), welche verschiedene Algorithmen kombinieren (Stochastic Gradient Descent) [Zh05]. Das textbasierte Submodell gibt dabei eine Klassifizierung (männlich oder weiblich) und eine Konfidenz – wie sicher sich das Submodell ist – aus und an das Metamodell weiter.

Auch der Name eines Nutzers kann Aufschluss über das Geschlecht geben. Während manche Nutzer hierdurch sehr gut klassifiziert werden können, zeigen andere Nutzerprofile lediglich eine Variation des eigenen Namens, ein Pseudonym oder gar einen irreführenden Namen an. Ziel der Namensanalyse ist es, mittels einer Datenbank, welche Namen zu

<sup>3</sup> Aus Gründen der besseren Lesbarkeit wird auf die gleichzeitige Verwendung männlicher und weiblicher Sprachformen verzichtet. Sämtliche Personenbezeichnungen gelten gleichwohl für beide Geschlechter.

einem oder mehreren Geschlechtern zuordnet<sup>4</sup>, das Geschlecht eines Nutzers herauszufinden. Hierfür betrachten wir den "Screen Name" und den "Display Name" eines Twitter Nutzers, welches im Profil angezeigt wird – z.B. "@John\_Doe1978" (Screen Name) und "John Doe" (Display Name). Zunächst werden beide Namen von Zahlen und Sonderzeichen befreit und Namensbestandteile werden identifiziert. Anschließend suchen wir in der Datenbank nach gleichen Namen. Wird kein identischer Name gefunden, nutzen wir die Levenshtein Distanz [Le66, Na01] um ähnliche Namen zu identifizieren. Zuletzt identifizieren wir das wahrscheinlichste Geschlecht. Auch das namensbasierte Submodell gibt eine Klassifizierung und eine Konfidenz aus und an das Metamodell weiter.

Auch das Nutzerbild kann ein Indiz für das Geschlecht eines Nutzers darstellen. Es wäre hier ebenfalls möglich – analog der Textvorhersage – ein eigenes überwachtes Lernmodell auf Basis von Nutzerbildern zu erstellen. Um die Flexibilität dieses Metamodellansatzes zu veranschaulichen, nutzen wir den kommerziellen Service IBM Watson Visual Recognition API [IB16], welcher auf Portraits von Menschen trainiert wurde. Wir senden die Nutzerbilder an den Web Service und bekommen das Geschlecht des Nutzers als Antwort zurück. Diese Antwort beinhaltet, wie bei den anderen beiden Submodellen, eine Klassifizierung und eine Konfidenz, welche wir an das Metamodell weiterreichen.




Abb. 2: Übersicht über Funktionsweise des kognitiven Metamodells

Schließlich bilden wir das Metamodell, welches nun die Ausgaben aller Submodelle in einer übergeordneten Sicht bewertet und eine gesamtheitliche Vorhersage des Geschlechts ausgibt. Wir wandeln die Ausgaben (Klassifizierung und Konfidenz) der Submodelle in einen Vektor um und nutzen diese als Eingabe für das Metamodell. Auch hier verwenden wir eine Kreuzvalidierung und Grid-Search um den besten Algorithmus und Parameterkombination für das Metamodell zu finden. Dabei stellen wir mit einer Sonderform der Kreuzvalidierung sicher, dass Training und Testsets getrennt sind und keine Instanz, trotz Unterteilung in Sub- und Metamodell in beiden Sets vorhanden ist. In Abbildung 2 zeigen wir den Prozess einer Klassifizierung anhand der drei Submodelle und dem finalen kognitiven Metamodell. Um den Nutzen des Metamodells zu verdeutlichen, testen wir zunächst einzelne Submodelle, die Kombination von textbasiertem und namensbasiertem Submodell und schließlich alle drei Submodelle vereint.

<sup>4</sup> namedict.txt von <https://heise.de/ct>, softlink 0717182 by Jörg Michael, zuletzt aufgerufen am 05.05.2017

### 3 Ergebnisse

Zur Messung der Qualität der Modelle berechnen wir jeweils den  $F_1$ -Wert als harmonische Abwägung zwischen Precision und Recall [Va79]. Für das textbasierte Modell erreichen wir einen  $F_1$ -Wert von 69,79%. Das namensbasierte Modell erreicht einen  $F_1$ -Wert von 69,06% und das bildbasierte Modell einen vergleichsweise schlechten  $F_1$ -Wert von 25,37%. Betrachtet man nun das Ergebnis des Metamodells, welches auf Basis des Textmodells und




Abb. 3: Verbesserung des  $F_1$ -Werts durch Miteinbeziehen weiterer Perspektiven in ein kognitives Metamodell

des Namensmodells trainiert wird, so kann mit einem  $F_1$ -Wert von 79,85% eine signifikante Modellverbesserung von 14,10 % ( $F_1$ ) zu dem besten unterliegenden Modell festgestellt werden. Dieser Wert wird durch das Metamodell mit allen drei Submodellen sogar um 16,72% ( $F_1$ ) mit einem  $F_1$ -Wert von 81,46% übertroffen. In Abbildung 3 veranschaulichen wir die Verbesserung des Modells durch die Kombination und die Zuhilfenahme mehrerer Quellen.

### 4 Fazit

Im Rahmen dieses Artikels haben wir die Möglichkeit von kognitiven Metamodellen für das Klassifizieren von deutschsprachigen Twitter Nutzern getestet. Dabei wird deutlich, dass mit zusätzlichen Submodellen (Text, Name, Profilbild) das Metamodell immer bessere Vorhersagen treffen kann – analog einem Menschen, der mit mehreren Sinnen beispielsweise eine gesteigerte Fähigkeit zu Überleben vorweist [Bu11a].

Die Forschungsarbeit hat einige Einschränkungen, so wurden die maschinellen Lernmodelle beispielsweise mit nur vergleichsweise wenig (2912) Daten trainiert. Ebenfalls wurde ein sehr spezifisches Beispiel – die Geschlechtererkennung auf Twitter – betrachtet. Es könnte weitere Fälle geben, in denen zusätzliche Sinne gegebenenfalls das Metamodell verschlechtern.

Ob dies der Fall ist, werden zukünftige Forschungsarbeiten mit anderen Fallbeispielen zeigen. Grundsätzlich scheint das Nachbilden kognitiver Fähigkeiten mit Metamodellen jedoch ein vielversprechender Ansatz zu sein, der in Zukunft weiter im Rahmen des Forschungsfeldes *Cognitive Computing* untersucht werden sollte.

**Literaturverzeichnis**

- [At10] Atrey, Pradeep K.; Hossain, M. Anwar; El Saddik, Abdulmotaleb; Kankanhalli, Mohan S.: Multimodal fusion for multimedia analysis: a survey. *Multimedia Systems*, 16(6):345–379, 2010.
- [Bu11a] Buchanan, Allen: *Better than human: the promise and perils of enhancing ourselves*. OUP USA, 2011.
- [Bu11b] Burger, John D; Henderson, John; Kim, George; Zarrella, Guido: *Discriminating Gender on Twitter*. Association for Computational Linguistics, 146:1301–1309, 2011.
- [Ca13] Cassidy, Andrew S.; Merolla, Paul; Arthur, John V.; Esser, Steve K.; Jackson, Bryan; Alvarez-Icaza, Rodrigo; Datta, Pallab; Sawada, Jun; Wong, Theodore M.; Feldman, Vitaly; Amir, Arnon; Rubin, Daniel Ben Dayan; Akopyan, Philipp; McQuinn, Emmett; Risk, William P.; Modha, Dharmendra S.: *Cognitive computing building block: A versatile and efficient digital neuron model for neurosynaptic cores*. Proceedings of the International Joint Conference on Neural Networks, 2013.
- [CDI06] Chella, A.; Dindo, H.; Infantino, I.: *A cognitive framework for imitation learning*. Robotics and Autonomous Systems, 54(5):403–408, 2006.
- [HCL08] Hsu, Chih-wei; Chang, Chih-Chung; Lin, Chih-Jen: *A Practical Guide to Support Vector Classification*. Bioinformatics, 1(1):1–15, 2008.
- [IB16] IBM: *Watson Visual Recognition service*, 2016.
- [KBMM08] Kludas, Jana; Bruno, Eric; Marchand-Maillet, Stéphane: *Information Fusion in Multimedia Information Retrieval*. In (Boujemaa, Nozha; Detyniecki, Marcin; Nürnberger, Andreas, Hrsg.): *Adaptive Multimedia Retrieval: Retrieval, User, and Semantics: 5th International Workshop, AMR 2007, Paris, France, July 5-6, 2007 Revised Selected Papers*. Springer Berlin Heidelberg, Berlin, Heidelberg, S. 147–159, 2008.
- [Ko99] Konar, Amit: *Artificial intelligence and soft computing: behavioral and cognitive modeling of the human brain*. CRC press, 1999.
- [Le66] Levenshtein, Vladimir I.: *Binary codes capable of correcting deletions, insertions, and reversals*. Soviet Physics Doklady, 10(8):707–710, 1966.
- [Lo68] Lovins, Julie Beth: *Development of a stemming algorithm*. Mechanical Translation and Computational Linguistics, 11(June):22–31, 1968.
- [Mo11] Modha, Dharmendra S.; Ananthanarayanan, Rajagopal; Esser, Steven K.; Ndirango, Anthony; Sherbondy, Anthony J.; Singh, Raghavendra: *Cognitive computing*. Communications of the ACM, 54(8):62, 2011.
- [MST94] Michie, Editors D; Spiegelhalter, D J; Taylor, C C: *Machine Learning, Neural and Statistical Classification*. Technometrics, 37(4):459, 1994.
- [Na01] Navarro, Gonzalo: *A guided tour to approximate string matching*. ACM Computing Surveys, 33(1):31–88, 2001.
- [OTO06] Ogiela, Lidia; Tadeusiewicz, Ryszard; Ogiela, Marek R.: *Cognitive computing in intelligent medical pattern recognition systems*. In: *Lecture Notes in Control and Information Sciences*. Jgg. 344, S. 851–856, 2006.

- [SLA12] Snoek, Jasper; Larochelle, Hugo; Adams, Ryan P: Practical Bayesian Optimization of Machine Learning Algorithms. *Adv. Neural Inf. Process. Syst.* 25, S. 1–9, 2012.
- [St77] Stone, M: Asymptotics For and Against Cross-Validation. *Biometrika*, 64(1):29–35, 1977.
- [TD03] Todorovski, Ljupco; Džeroski, Sašo: Combining classifiers with meta decision trees. *Machine Learning*, 50(3):223–249, 2003.
- [Va79] Van Rijsbergen, C J: *Information Retrieval*. Butterworths & Co, 1979.
- [Wa03] Wang, Yingxu: On Cognitive Informatics. *Brain and Mind*, 4(2):151–167, 2003.
- [Yi09] Yingxu Wang, University of Calgary, Canada Jean-Claude Latombe, Stanford University, USA Du Zhang, California State University, Sacramento, USA Witold Kinsner, University of Manitoba, Canada: *Advances in Cognitive Informatics and Cognitive Computing*:. *International Journal of Cognitive Informatics and Natural Intelligence*, 3(4):91–95, 2009.
- [Zh05] Zhou, GuoDong; Shen, Dan; Zhang, Jie; Su, Jian; Tan, SoonHeng: Recognition of protein/gene names from text using an ensemble of classifiers. *BMC bioinformatics*, 6(1):1, 2005.