

Gasquellenlokalisierung mit Drohnenschwärmen

Felix Häusler und Jan Stührenberg

Institut für Digitales und Autonomes Bauen, Technische Universität Hamburg, Blohmstraße 15,

21079 Hamburg, Deutschland

E-Mail: jan.stuehrenberg@tuhh.de

Abstract: Gasquellenlokalisierungen (Gas Source Localization, GSL) tragen dazu bei, die Folgen von Industrieunfällen und Naturkatastrophen zu mildern. Während die GSL, wenn von Menschen durchgeführt, gefährlich und zeitaufwändig ist, können Schwärme von wendigen und kostengünstigen Nanodrohnen die Effizienz und Sicherheit der Suche erhöhen. Da die geringe Nutzlast von Nanodrohnen die Sensor- und Rechenressourcen einschränkt, werden Strategien zur Koordination des Roboterschwarms verwendet, die von biologischen Schwärmen, wie Kolonien sozialer Insekten, inspiriert sind. Die meisten Schwarm-GSL-Strategien verwenden das Maximum der Gaskonzentrationsverteilung zur Schätzung der Gasquellenposition. Experimente legen jedoch nahe, dass die Intermittenz der Gasverteilung vielversprechender ist. In diesem Beitrag wird eine neuartige GSL-Strategie für Schwärme vorgestellt, die auf Pheromonkommunikation und Intermittenz der Gasverteilung basiert. Die Agenten, d.h. die Nanodrohnen, emittieren Pheromonmarker in einer virtuellen Umgebung, wenn sie eine neue Gaswolke feststellen. Die Agenten werden durch virtuelle Kräfte gesteuert und nutzen abwechselnd das Wissen des Schwarms, indem sie dem Pheromongradienten folgen, oder erkunden den Suchraum, indem sie einen Zufallspunkt ansteuern. Zur Kollisionsvermeidung werden die Agenten durchgehend von anderen Agenten und Wänden abgestoßen. Die Strategie wurde auf drei Nanodrohnen implementiert und durch ein Experiment in einem Innenraum mit einer statischen Gasquelle validiert. Die Ergebnisse zeigen eine Verbesserung gegenüber maximabasierten Verfahren und geringe Lokalisierungsfehler in Windrichtung.

Keywords: Bouts, Mobile Sensorik, Nanodrohnen, Pheromonkommunikation, Schwarmrobotik



Erschienen in Tagungsband 34. Forum Bauinformatik 2023, Bochum, Deutschland, DOI: 10.13154/294-10088

© 2023 Das Copyright für diesen Beitrag liegt bei den Autoren. Verwendung erlaubt unter Creative Commons Lizenz Namensnennung 4.0 International.

1 Einleitung

Gasquellenlokalisierungen (GSL) mit mobilen Robotern sind bei vielen industriellen, umwelttechnischen und humanitären Aufgaben von Nutzen, bei denen die Suchräume gefährlich und/oder

schwierig zu erreichen sind. In den letzten Jahren wurden Roboterschwärme bereits erfolgreich zur automatisierten Durchführung von Ingenieuraufgaben eingesetzt, wie dem Monitoring von Bauwerken [1]. Auch zur Gasquellenlokalisierungen ist der Einsatz von Roboterschwärmen vielversprechend, erfordert aber zuverlässige Koordinierungskonzepte. Biologische Schwärme, wie Populationen sozialer Insekten, sind eine beliebte Inspirationsquelle, um eine solche Koordination zwischen einer großen Anzahl relativ einfacher Agenten zu erreichen. Die meisten von Schwärmen inspirierten Forschungsarbeiten auf dem Gebiet der Mobile Robot Olfaction (MRO) behandeln GSL als ein Konzentrationsoptimierungsproblem, das auf der Annahme beruht, dass das Maximum der Gaskonzentration in der Nähe des tatsächlichen Quellortes liegt [2]. Unter dieser Annahme können bestehende Schwarmintelligenz-Algorithmen für GSL verwendet werden. Die Bekanntesten sind die Partikel-schwarmoptimierung und der Ameisenalgorithmus [3], die zwar für viele Anwendungsfälle validiert sind, aber im Allgemeinen nicht die physikalischen und dynamischen Aspekte der realen Welt berücksichtigen. Die direkte Inspiration durch biologische Schwärme könnte zu einfacheren, aber effizienteren Algorithmen führen, da biologische Schwärme unter ähnlichen Bedingungen arbeiten wie Roboterschwärme. Darüber hinaus haben mehrere Studien gezeigt, dass das Konzentrationsmaximum in komplexen Umgebungen nicht unbedingt ein guter Indikator für die Nähe der Gasquelle ist und dass die Unterbrechung der Gaswolke, gemessen durch so genannte Bouts, eine bessere Wahl sein könnte [4].

Der Hauptbeitrag dieser Arbeit ist die Einführung einer neuartigen Schwarmstrategie, die Bouts als Näherungsindikator und eine schwarminspirierte Pheromonkommunikation verwendet (Kapitel 2), und ihre Validierung in Simulationen (Kapitel 3.1) und realen Experimenten (Kapitel 3.2): Die Agenten erkennen Bouts und senden künstliche Pheromone aus, die, sobald sie in eine Karte integriert sind, zur Navigation und Kollisionsvermeidung verwendet werden. Das Gleichgewicht zwischen Erkundung des Suchraums und Erschließung vielversprechender Bereiche wird durch gelegentliches Ignorieren der Pheromonkarte erreicht. Die höchste Pheromonkonzentration zeigt die geschätzte Position der Quelle an. Der in dieser Arbeit aufgeführte Ansatz ist zwar nicht die erste Strategie, die Pheromonkommunikation einsetzt [5], aber er integriert, speichert und verbreitet die Pheromonsignale, macht sie skalierbar, robust gegenüber Rauschen und Defekten, reagiert auf Änderungen der Position der Quelle und vereinfacht die Agenten auf eine rein reaktive Rolle.

2 Algorithmus zur Bout-basierten Gasquellenlokalisierung

Der in dieser Arbeit vorgeschlagene Algorithmus besteht aus zwei Teilen: der künstlichen Umgebung, die den Schwarm koordiniert, und den Agenten, die Messungen durchführen und Pheromone an die künstliche Umgebung abgeben, wenn Bouts entdeckt werden. Im Folgenden werden beide Teile und ihre Interaktionen vorgestellt.

Die künstliche Umgebung soll es den Agenten ermöglichen, effektiv zu kollaborieren. Dies wird durch das Konzept des künstlichen Potentialfelds (Artificial Potential Field, APF) [6] realisiert. Auf

Anforderung erhalten die Agenten die anziehende Kraft der künstlichen Pheromonkarte (Artificial Potential Map, APM) und die abstoßende Kraft der Antikollisionsschicht. Die APM ahmt den Umweltanteil in der biologischen Pheromonkommunikation nach. Die APM ermöglicht es, (i) eine beliebige Anzahl von Signalen in eine Raumfunktion zu integrieren und (ii) die Funktion über die Zeit zu verbreiten. Der erste Aspekt ermöglicht es einer beliebigen Anzahl vereinfachter Organismen zu kollaborieren, ohne sich gegenseitig zu bemerken, und der zweite ermöglicht es dem System, probabilistisch zu arbeiten, da die Wirkung einzelner Marker verblasst, wenn sie nicht verstärkt wird. Die APM wird durch eine diskrete Karte dargestellt, auf der die Agenten an ihrer aktuellen Position Pheromonmarker – Partikel mit vordefinierter Größe und Intensität – freisetzen können. Jedes Mal, wenn ein neuer Pheromonmarker freigesetzt wird, wird ein Diffusionskern auf die Karte angewendet. Dadurch werden neuere Marker höher gewichtet als frühere und es wird verhindert, dass Informationen verloren gehen, wenn keine neuen Pheromone abgelegt werden. Um die Anziehungskraft zu berechnen, wird eine kernelgeglättete Kopie der APM in ein APF umgewandelt. Dabei regelt die Kernelgröße den Einflussbereich der Pheromonmarker. Als nächstes wird der Gradient oder die Kraft des APF berechnet und gemäß dem folgenden Ausdruck verwirbelt:

$$F_{\text{vortex},x} = F_x + F_y \cdot \gamma, \quad (1a)$$

$$F_{\text{vortex},y} = F_y - F_x \cdot \gamma, \quad (1b)$$

wobei $F_{\text{vortex},x/y}$ die resultierende verwirbelte Kraft, $F_{x/y}$ die ursprüngliche Kraft in x/y-Richtung und γ ein Faktor ist, der die Wirbelstärke und die Spinrichtung bestimmt. Die Verwirbelung veranlasst die Agenten, vielversprechende Gebiete zu umkreisen, anstatt direkt auf den Pheromon-Peak zuzusteuern, und hilft ihnen so, lokale Optima zu vermeiden. Das verwirbelte Kraftfeld wird schließlich normalisiert, was wichtig ist, um Kollisionen zu vermeiden. Wenn ein Agent die Kräfte an seiner Position abfragt, werden das resultierende Kraftfeld und die Abstoßungskraft zurückgegeben. Zur Antikollision wird für jeden Agenten eine Abstoßungskraft $F_{\text{rep.}}$ basierend auf dem Abstand zu Hindernissen und anderen Agenten unter Verwendung einer Adaption der FIRAS-Funktion aus [6] berechnet:

$$F_{\text{rep.}} = \begin{cases} \left(\frac{d_{\min}^2}{\frac{1}{d_{\min}} - \frac{1}{d_{\max}}} \right) \left(\frac{1}{d} - \frac{1}{d_{\max}} \right) \frac{1}{d^2}, & \text{wenn } d \leq d_{\max} \\ 0, & \text{sonst} \end{cases} \quad (2)$$

wobei d die Entfernung zwischen dem anfragenden Agenten und dem Hindernis darstellt und d_{\min} und d_{\max} Parameter für die geringste zulässige Entfernung und den Einflussbereich des Hindernisses sind. Beide Parameter müssen auf der Grundlage der verfügbaren Positionierungsgenauigkeit und der Entfernung, die die Agenten sicher aneinander vorbeifahren können, gewählt werden. Für eine optimale Navigation sollten APM- und Antikollisionskräfte die gleiche Drehrichtung haben, was eine umgekehrte Drehung für die Abstoßungskräfte der umschließenden Wand erfordert. Die Rotation hilft, Deadlocks bei der Hindernisvermeidung zu vermeiden.

Agenten werden auf reaktive Partikel mit einem Bout-Detektor und einer Bewegungssteuerung reduziert. Der Bout-Detektor wurde aus [7] übernommen: Die Agenten überwachen die zweite Ableitung des Konzentrationssignals auf einen positiven Nulldurchgang, der als Bout bezeichnet wird. Ein Bout zeigt an, dass der Sensor mit einer neuen Gaswolke in Berührung gekommen ist. Rauschbedingte Bouts werden durch einen Schwellenwert gefiltert, während Bouts, die einen Schwellenwert nicht überschreiten, verworfen werden. Das Rohsignal und beide Ableitungen werden vor der weiteren Verarbeitung mit einem exponentiell gewichteten gleitenden Durchschnittsfilter geglättet. Die Positionen der akzeptierten Bouts werden an die künstliche Umgebung gesendet, die die Bouts als Pheromonmarker in die APM integriert.

Die Bewegungssteuerung steuert die Agenten, die entweder der Anziehungskraft der APM folgen, um Schwarmwissen zu nutzen, oder der Anziehungskraft einer zufällig generierten Sollposition, um den Suchraum zu erkunden. Die Anziehungskraft der Sollposition $\vec{F}_{\text{set.}}$ ist definiert durch:

$$\vec{F}_{\text{set.}} = \begin{cases} \frac{\vec{X}_{\text{set.}} - \vec{X}_{\text{pos.}}}{\|\vec{X}_{\text{set.}} - \vec{X}_{\text{pos.}}\|}, & \text{wenn } \|\vec{X}_{\text{set.}} - \vec{X}_{\text{pos.}}\| > \varepsilon \\ \frac{\vec{X}_{\text{set.}} - \vec{X}_{\text{pos.}}}{\varepsilon}, & \text{sonst} \end{cases} \quad (3)$$

$\vec{X}_{\text{pos.}}$ und $\vec{X}_{\text{set.}}$ sind die Positionsvektoren des Agenten bzw. der Sollposition, und ε ist der Abstand in der der Agent linear verlangsamt. Anschließend wird die resultierende Kraft normalisiert und mit der maximalen linearen Geschwindigkeit multipliziert, um den Geschwindigkeitsvektor zu erhalten, der an die Low-Level-Steuerung der Nanodrohne weitergeleitet wird.

3 Implementierung und Validierung

Der Schwarm, der zur Validierung verwendet wird, besteht aus handtellergroßen Crazyflie 2.0 Quadcoptern [8], die mit einem lokalen 3D-Positionierungssystem und einem speziell angefertigten Sensorendeck ausgestattet sind, das aus einem optischen Bewegungserkennungssystem und zwei SGP30 Metalloxid-Halbleiter-Gassensoren [9] besteht [10]. Bouts werden anhand des transienten Signals des Ethanol-Pixels des Gassensors erkannt. Der komplette Aufbau wiegt ca. 39,6 g und erreicht Flugzeiten von bis zu 5 Minuten. Die vorgestellte Strategie wird über die Crazyswarm Python API [11] und das Robot Operating System (ROS) implementiert.

3.1 Simulation

Das Potenzial von Bouts zur Schätzung der Gasquellenposition wurde in Simulationen mit GADEN [12], einem Simulations-Framework, das für Algorithmen im Bereich der MRO entwickelt wurde, validiert. In einer simulierten Umgebung wurden 12 Agenten in einem (6×10) m² großen Raum mit zwei

Öffnungen, von denen eine als Einlass und die andere als Auslass diente, eingesetzt, in dem eine einzige Gasquelle an (3,0; 1,5; 0,75) m positioniert wurde. Es wurde das von GADEN vorberechnete Windfeld verwendet, das aus einer starken, fluktuierenden Luftströmung besteht. Die Agenten durchquerten den Raum zufällig in einer Höhe von 0,5 m und zeichneten ihre Sensormessungen und Positionen mit 10 Hz auf. Die Simulation lief 30 Minuten lang mit 10-facher Beschleunigung.

Während der Simulation wurden ca. 180.000 Sensormessungen aufgezeichnet. Abb. 1(a) zeigt die mittleren Sensormesswerte (niedrigere Widerstände entsprechen höheren Konzentrationen) und Abb. 1(b) zeigt die Gesamtzahl der Bouts je Zelle, beide visualisiert in diskreten Karten des Suchraums. Beide Karten zeigen eine Anhäufung von Zellen mit niedrigen Widerständen bzw. hoher Anzahl von Bouts in der Nähe der Gasquelle, wenn auch 1,5 m in Richtung des Luftstroms versetzt. Während die Gradienten in Abb. 1(a) relativ glatt sind und keine Grenzen sichtbar sind, zeigt Abb. 1(b) eine deutlich dichtere V-förmige Verteilung mit steilen Gradienten in Abwindrichtung. Die Simulationsergebnisse deuten darauf hin, dass die Anzahl der Bouts ein genauerer und rauschärmerer Indikator für die Nähe der Quelle sein kann als die mittlere Konzentration.

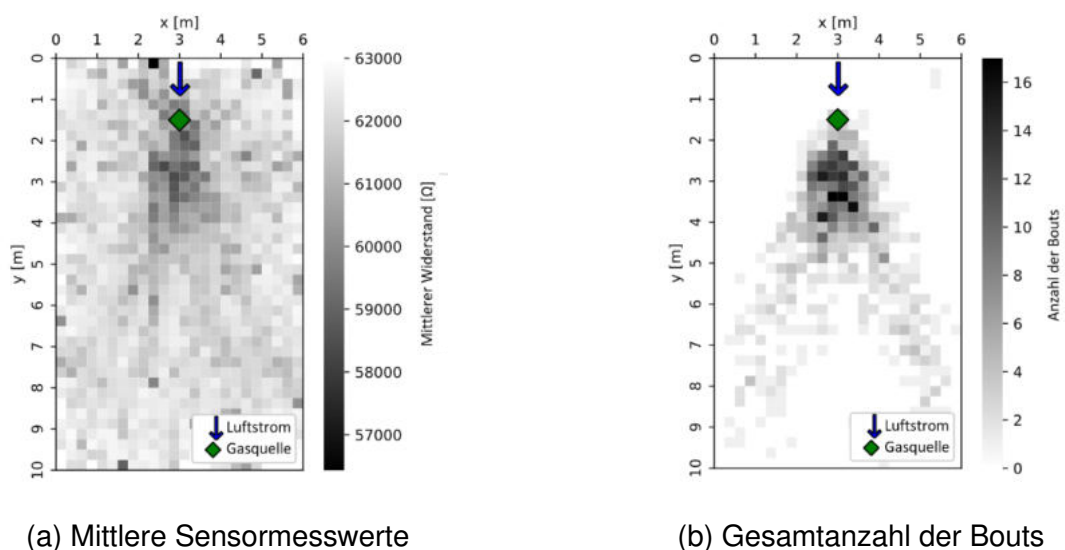


Abbildung 1: Karten der simulierten Sensordaten

3.2 Experimente in der realen Welt

Die Validierung der in Kapitel 2 beschriebenen GSL-Strategie wird durch reale Experimente mit einem aus drei Nanodrohnen bestehenden Schwarm bestätigt, die in Kapitel 3 vorgestellt wurden. Der Schwarm wurde in einem quaderförmigen Innenraum mit einem 2D-Suchraum von ca. (3×3) m² eingesetzt, der eine einzige Gasquelle enthält. Die Gasquelle, bestehend aus einem Schlauch, der an eine Flasche mit flüssigem Ethanol und einem 1-W-Ventilator angeschlossen war, wurde an (0,80; 0,75) m positioniert und befand sich 0,1 m über dem Boden. Um die Verdunstung anzuregen, wurde Druckluft eingeleitet, und die Emissionsrate wurde indirekt durch Einstellung des Luftstroms

auf 2 l/min gesteuert. Die Gasquelle wurde so gedreht, dass sie auf die Mitte des Suchraums ausgerichtet war, und etwa eine Minute vor jedem Lauf geöffnet. Zwischen den Läufen wurde die Quelle geschlossen und der Raum gelüftet, um vergleichbare Startbedingungen zu schaffen. Die Nanodrohnen beendeten jeden Lauf entweder durch Landung/Absturz oder durch Leerlaufen des Akkus. Die für den Algorithmus erforderlichen Parameter wurden heuristisch gewählt, und die Daten wurden mit 10 Hz aufgezeichnet. Der Versuchsaufbau ist in Abbildung 2 dargestellt.

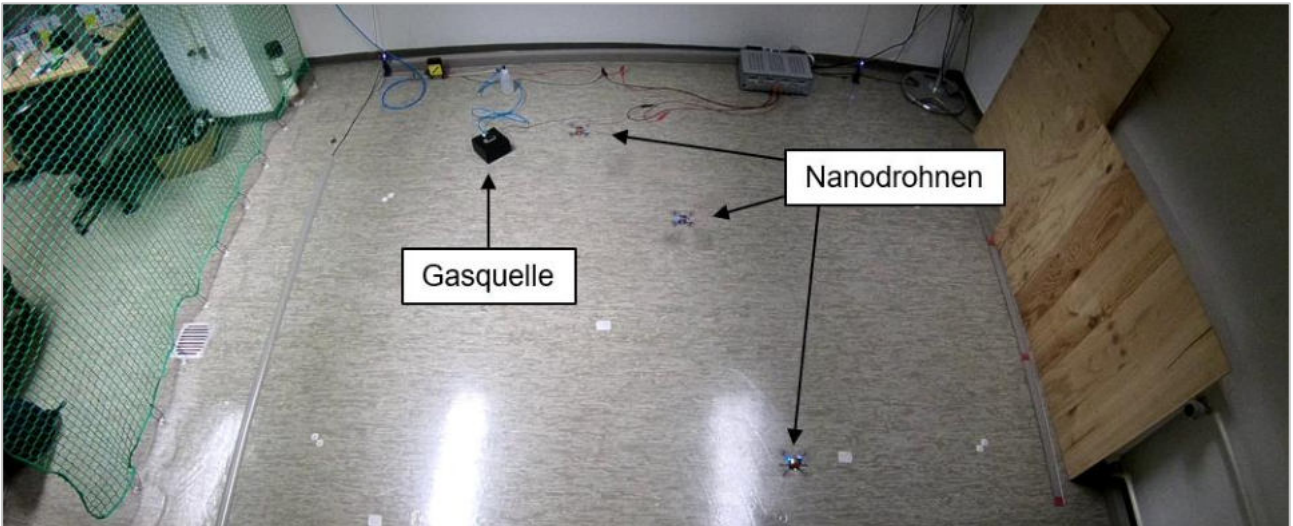
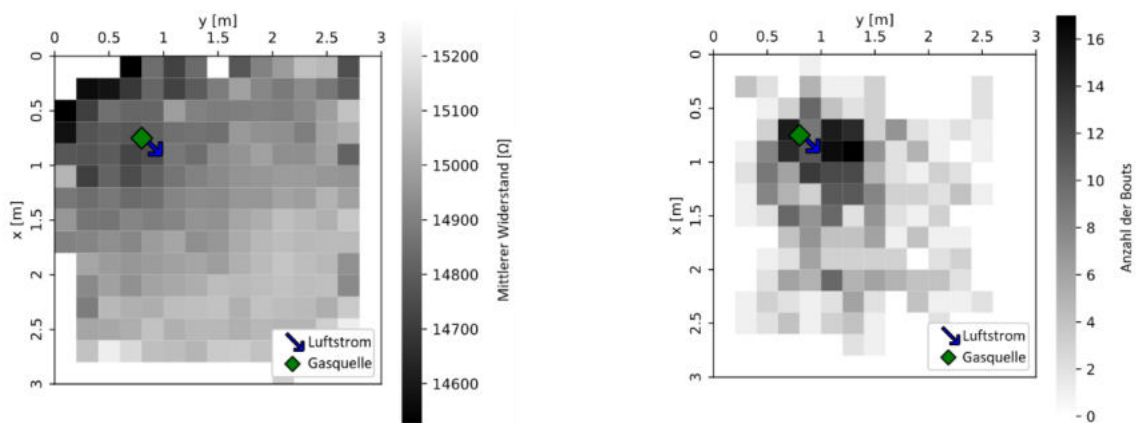


Abbildung 2: Versuchsaufbau für die Experimente in der realen Welt

Während der 16 Läufe wurden ca. 20.000 Messungen aufgezeichnet. Die einzelnen Flugzeiten lagen in einem Bereich von 0 s (Absturz beim Start) bis 329 s, und die kombinierten Flugzeiten aller drei Nanodrohnen lagen in einem Bereich von 303 s bis 903 s mit einem Mittelwert von $613,4 \pm 165,2$ s. Die experimentellen Ergebnisse sind in Abb. 3 und 4 dargestellt. Das Diagramm des mittleren Widerstands in Abb. 3(a) zeigt glatte Gradienten, ähnlich wie in Abb. 1(a). Im Gegensatz zu



(a) Mittlere Sensormesswerte

(b) Gesamtanzahl der Bouts

Abbildung 3: Karten der experimentellen Sensordaten

Abb. 1(a) ist jedoch der Cluster der niedrigen mittleren Widerstände in Aufwindrichtung verschoben. Die Bout-Verteilung in Abb. 3(b) zeigt wiederum dichte Cluster mit steilen Gradienten, aber im Gegensatz zu den Simulationsergebnissen ist keine V-Form sichtbar. Abb. 4(a) zeigt die endgültigen Schätzungen der Gasquellenposition. Alle Schätzfehler liegen in Richtung der Luftströmung. Außerdem liegt der mittlere Fehler in der Nähe der Mittellinie des Luftstroms des Ventilators. Abb. 4(b) zeigt den durchschnittlichen Schätzfehler der kombinierten Flugzeit, skaliert mit der Anzahl der aktiven Agenten, einschließlich der Ergebnisse jedes einzelnen Laufs. Die Schätzung der Gasquellenposition verbessert sich im Mittel während der ersten 90 s kombinierter Flugzeit schnell.




Abbildung 2: Experimentelle Ergebnisse: (a) Finale Schätzungen der Gasquellenposition und (b) geglätteter mittlerer Fehler der kombinierten Flugzeit der Versuche mit Standardabweichung über die Zeit, Laufzeit individuell skaliert durch die Anzahl der aktiven Agenten

4 Schlussfolgerung und zukünftige Arbeiten

In diesem Beitrag wurde ein neuartiger Schwarm-GSL-Ansatz vorgestellt, der Bouts als Indikator für die Nähe von Gasquellen und virtuelle Pheromone als Kommunikationsmedium verwendet. Simulationen und reale Experimente haben gezeigt, dass Bouts in einfachen Innenräumen im Vergleich zur mittleren Konzentration starke Indikatoren für die Nähe zu einer Quelle sein können. Darüber hinaus zeigt die Strategie in realen Experimenten vielversprechende Ergebnisse, obwohl sie noch in den Kinderschuhen steckt: Zukünftige Arbeiten werden sich darauf konzentrieren, den Parametersatz der Methode abzustimmen und sie zu verbessern, z. B. durch die Einführung von Windinformationen und die Erweiterung auf drei Dimensionen. Außerdem sollte die Strategie mit bestehenden Algorithmen unter identischen Umweltbedingungen verglichen werden.

Danksagung

Die Autoren bedanken sich bei Patrick Neumann und der Bundesanstalt für Materialforschung und -prüfung für die Unterstützung und Bereitstellung der Nanodrohnen und des Versuchsaufbaus.

Literaturverzeichnis

- [1] K. Smarsly, M. Worm, and K. Dragos, "Design and validation of a mobile structural health monitoring system based on legged robots," In Proc. 29th International Workshop on Intelligent Computing in Engineering, Aarhus, Denmark, 07/08/2022.
- [2] T. Jing, Q.-H. Meng, and H. Ishida, "Recent progress and trend of robot odor source localization," *IEEE Transactions on Electrical and Electronic Engineering*, vol. 16, no. 7, pp. 938-953, 2021.
- [3] J. Wang, Y. Lin, R. Liu, and J. Fu, "Odor source localization of multi-robots with swarm intelligence algorithms: A review," *Frontiers in Neurobotics*, vol. 16, 2022.
- [4] M. Schmuker, V. Bahr, and R. Huerta, "Exploiting plume structure to decode gas source distance using metal-oxide gas sensors," *Sensors and Actuators B: Chemical*, vol. 235, pp. 636-646, 2016.
- [5] Q.-H. Meng, W.-X. Yang, Y. Wang, and M. Zeng, "Multi-robot odor-plume tracing in indoor natural airflow environments using an improved ACO algorithm," In Proc. 2010 IEEE International Conference on Robotics and Biomimetics, Tianjin, China, 12/14/2010.
- [6] O. Khatib, "Real-time obstacle avoidance for manipulators and mobile robots," in Proc. 1985 IEEE International Conference on Robotics and Automation, St. Louis, MO, USA, 03/25/1985.
- [7] J. Burgués, V. Hernández, A. J. Lilienthal, and S. Marco, "Smelling nano aerial vehicle for gas source localization and mapping," *Sensors*, vol. 19, no. 3, 478, 2019.
- [8] Bitcraze AB, "Crazyflie 2.0". [Online]. Available: <https://www.bitcraze.io/products/old-products/crazyflie-2-0/> [Accessed May 9, 2023].
- [9] Sensirion AG, "Datasheet SGP30", May 2020. [Online]. Available: https://sensirion.com/media/documents/984E0DD5/61644B8B/Sensirion_Gas_Sensors_Datasheet_SGP30.pdf [Accessed May 9, 2023].
- [10] P. P. Neumann, P. Hirschberger, Z. Baurzhan, C. Tiebe, M. Hofmann, D. Hüllmann, and M. Bartholmai, "Indoor air quality monitoring using flying nanobots: Design and experimental study," In Proc. 2019 IEEE International Symposium on Olfaction and Electronic Nose, Fukuoka, Japan, 05/26/2019.
- [11] J. A. Preiss, W. Honig, G. S. Sukhatme, and N. Ayanian, "Crazyswarm: A large nano-quadcopter swarm," In Proc. 2017 IEEE International Conference on Robotics and Automation, Singapore, 05/29/2017.
- [12] J. Monroy, V. Hernandez-Bennets, H. Fan, A. Lilienthal, and J. Gonzalez-Jimenez, "GADEN: A 3D gas dispersion simulator for mobile robot olfaction in realistic environments," *Sensors*, vol. 17, no. 7, 1479, 2017.