

Experimente zur hochpräzisen landmarkenbasierten Eigenlokalisierung in unsicherheitsbehafteten digitalen Karten

Henning Lategahn* und Christoph Stiller*

Zusammenfassung: Zukünftige Fahrerassistenzsysteme benötigen eine präzise Kenntnis über die eigene Fahrzeugpose. Überlicherweise wird dieses Problem durch Satellitennavigationssysteme adressiert. Diese liefern häufig jedoch eine Posenschätzung die weit unter der Genauigkeit liegt, die beispielsweise für autonomes Fahren benötigt wird.

In diesem Beitrag stellen wir eine Fahrzeugeigenlokalisierung vor, die das Fahrzeug relativ zu einer Landmarkenkarte lokalisiert. Zu diesem Zweck werden die in der Karte enthaltenen Landmarken mit einer Monokamera detektiert. Die Eigenpose wird danach mittels nichtlinearer Ausgleichsrechnung bestimmt. Besonderes Augenmerk wird auf das Erkennen grob fehlerhafter Messungen (Ausreißern) gelegt. Die hier vorgestellte Methodik kann Entscheidungen über die Validität einer vergangen Messung nachträglich revidieren. Des Weiteren zeigen wir, dass bei einer unsicherheitsbehafteten Karte die Fahrzeugpose genauer geschätzt werden kann, wenn die Landmarken der Karte simultan mit geschätzt werden.

In Experimenten kann eine Lokalisierungsgenauigkeit von 10cm erreicht werden.

Schlüsselwörter: Eigenlokalisierung, Landmarken, Nichtlineare Ausgleichsrechnung

1 Einleitung

Fahrerassistenzsysteme der nächsten Generation benötigen eine genaue Eigenlokalisierung. Zukünftige Navigationssysteme könnten beispielsweise den zu fahrenden Pfad mittels Head-Up-Displays direkt auf der Fahrbahn anzeigen und so die Navigation für den Fahrer erheblich erleichtern. Des Weiteren ermöglicht eine präzise Lokalisierung in Kombination mit digitalen Strassenkarten eine Vielzahl an Funktionen. Automatisches Spurhalten, Erkennung von Ampelanlagen oder teil-autonomes Fahren werden durch eine genau bekannte Eigenposition innerhalb einer digitalen Karte erheblich unterstützt.

Heutzutage werden satellitengestützte Verfahren zu diesem Zwecke verwendet. Differenzielles GPS wird hierzu mit Inertialsensorik kombiniert und liefert so eine Positionsbestimmung. Die Genauigkeit dieser System ist jedoch stark von einer guten Sichtbarkeit hinreichend vieler Satelliten abhängig. Insbesondere in städtischen Szenarien mit tiefen Häuserschluchten oder dichter Vegetation ist diese unzureichend. Ausserdem finden solche System auf Grund ihrer hohen Kosten nur in Experimentalfahrzeugen Verwendung.

*Institut für Mess- und Regelungstechnik, Karlsruher Institut für Technologie, 76128 Karlsruhe e-mail: {henning.lategahn,christoph.stiller}@kit.edu

Als Alternative zu satellitengestützten Verfahren sind kürzlich Methoden zur kartenbasierten Lokalisierung erarbeitet worden. Ziel ist es hier, das Egofahrzeug innerhalb einer vorher aufgezeichneten Karte zu lokalisieren. Sensormessungen werden unter Zuhilfenahme der Karte zu einer Positionsbestimmung ausgewertet. Beispiele sind die Arbeiten in [1, 4, 7, 8]. Grundsätzlich benötigen diese Verfahren keine Satellitenunterstützung und kommen mit der fahrzeugeigenen Sensorik aus. Die Vorteile dieser Vorgehensweise sind offensichtlich. Die Lokalisierung funktioniert auch in Situationen, die für herkömmliches GPS sehr schwierig sind, die Sensorik ist kostengünstiger und die Wiederholgenauigkeit ist nicht von atmosphärischen Störungen beeinflusst. Die Methode ist verwandt mit sogenannten *Simultaneous Localization and Mapping* (SLAM) Ansätzen. Beispiele finden sich in [2, 6].

In diesem Beitrag stellen wir eine Lokalisierungslösung vor, die lediglich eine Monokamera und Odometrie benötigt. Die Kamera misst den Winkel zu natürlichen Landmarken einer Landmarkenkarte. Odometriemessungen liefern eine verrauschte Bewegungsschätzung zwischen je zwei aufeinander folgenden Posen. Diese Messungen werden dann in einer nichtlinearen Ausgleichsrechnung kombiniert um eine Eigenpose zu berechnen. Besonderes Augenmerk wird dabei auf den Umgang mit der Unvollkommenheit der Landmarkenkarte gelegt. Es kann nicht erwartet werden, dass die Positionen der Landmarken innerhalb der Karte vollkommen exakt sind. Des Weiteren kann es bei der Landmarkenassoziation leicht zu Falschzuordnungen kommen. Daher schlagen wir vor, Fehlzusammenordnungen zu detektieren und gleichzeitig die Positionen der Landmarken innerhalb der Karte online mit zu schätzen.

2 Methodik

Im folgenden stellen wir das Problem der Posenschätzung mit einer unsicherheitsbehafteten Karte vor. Danach wird der hier vorgeschlagene Lösungsansatz erläutert.

2.1 Landmarkenkarte

Abbildung 1 zeigt schematisch den Aufbau der digitalen Karte. Landmarken sind in blau (Kreis) dargestellt und durch ihr 2d Position parametrisiert $l_j = (X_j, Y_j)^T$. Posen werden mit p_i bezeichnet und sind hier in gelb dargestellt. Eine Pose wird durch ihre Position und Gierwinkel parametrisiert $p_i = (x_i, y_i, \theta_i)^T$. Die exakte Bewegung von Pose p_{i-1} zu Pose p_i wird mit $o_i = (\Delta x_i, \Delta y_i, \Delta \theta_i)^T$ bezeichnet. Als Beobachtungsgröße einer Monokamera wird der Winkel α_{ij} einer Landmarke l_j zur Pose p_i verwendet.

Entscheidend ist nun, dass keine der vorherig genannten Größen exakt bekannt ist. Vielmehr stehen lediglich ihre verrauschten Schätzungen zur Verfügung. Diese sind wie folgt modelliert

$$\bar{l}_j = l_j + \epsilon_j \quad (1)$$

$$\bar{o}_i = o_i + \zeta_i \quad (2)$$

$$\bar{\alpha}_{ij} = \alpha_{ij} + \eta_{ij} \quad (3)$$

wobei ϵ_j , ζ_i und η_{ij} jeweils unkorreliertes gaußsches Rauschen mit bekannten Kovarianzmatrizen bezeichnen. Die digitale Landmarkenkarte besteht somit aus den L unsicherheitsbe-

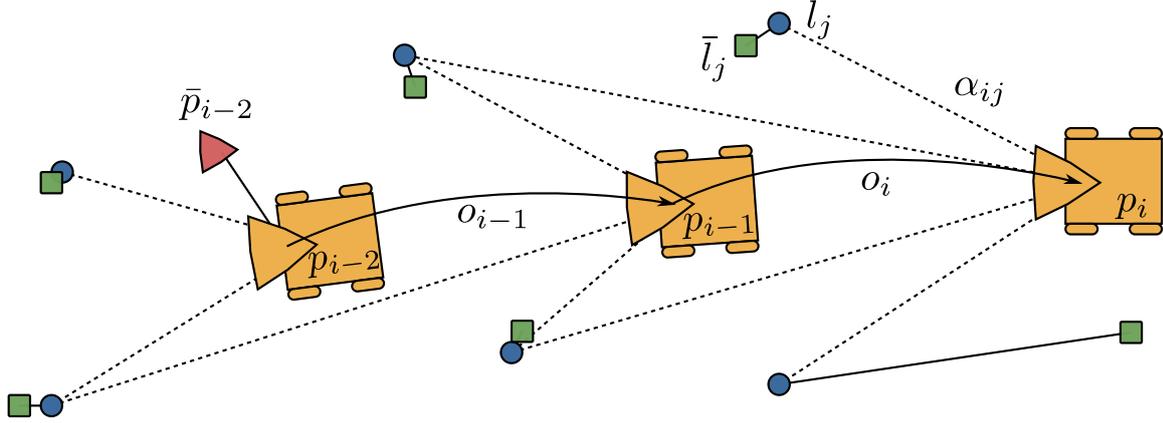


Abbildung 1: Digitale Landmarkenkarte mit nach hinten gerichteter Kamera. Die exakten Positionen der Landmarken sind in blau (Kreise) dargestellt. Jedoch ist nur eine verrauschte Version der Karte bekannt (grün/Quadrat). Einige Landmarken sind grob fehlerbehaftet eingetragen (rechts unten) und stellen Fehlmessungen (Ausreißer) dar. Eine grobe Schätzung der ersten Pose ist in rot (Dreieck) dargestellt.

hafteten Positionen der Landmarken $\{\bar{l}_1, \dots, \bar{l}_L\}$. Diese sind in der Skizze 1 grün (Quadrat) dargestellt. Darüber hinaus steht eine Schätzung der ersten Pose $\bar{p}_{i-F+1} = p_{i-F+1} + \nu_{i-F+1}$ aus vorherigen Zeitschritten zur Verfügung wobei F die Fensterlänge bezeichnet. Eine solche Posenschätzung ist in rot (Dreieck) in der Skizze dargestellt.

Ausserdem sind manche der Landmarken weit von ihrer eigentlichen Position in der Karte eingetragen und verursachen fehlerhafte Messungen (Ausreißer), die während der Schätzung erkannt werden müssen.

2.2 Eigenlokalisierung

Das Ziel der Eigenlokalisierung ist nun, aus den in Abschnitt 2.1 eingeführten Messungen $\bar{l}_j, \bar{o}_i, \bar{\alpha}_{ij}, \bar{p}_{i-F+1}$, die aktuelle Fahrzeugpose zu schätzen. Dazu werden die letzten F Posen und alle Landmarken, die von diesen Posen gemessen wurden, simultan geschätzt. Der zu berechnende Zustandsvektor ist somit $\mathbf{x} = (p_{i-F+1}, \dots, p_i, \dots, l_j, \dots)^T$. Alle Messungen werden im Messvektor $\mathbf{z} = (\bar{p}_{i-F+1}, \dots, \bar{l}_j, \dots, \bar{o}_i, \dots, \bar{\alpha}_{ij}, \dots)^T$ zusammen gefasst.

Da die Positionen der Landmarken während der Lokalisierung mitgeschätzt werden, müssen diese auch als Teil der Messgleichung auftauchen. Die Landmarken (l_j) werden also einfach im ersten Teil des erwarteten Messvektors aufgeführt. Gleiches gilt für die *a-priori* Annahme der ersten Pose des Posenfensters (p_{i-F+1}). Eine Odometriemessung kann aus der Schätzung zweier Posen p_i und p_{i-1} durch Posensubtraktion prädiziert werden ($p_i \ominus p_{i-1}$). Der relative Winkel einer Landmarke l_j zur Pose p_i wird berechnet durch $\arctan\left(\frac{Y_j - y_i}{X_j - x_i}\right) -$

θ_i . Der sich aus einer Schätzung ergebene Fehlervektor ist somit:

$$e(\mathbf{x}) = \begin{pmatrix} p_{i-F+1} \\ \vdots \\ l_j \\ \vdots \\ p_i \ominus p_{i-1} \\ \vdots \\ \arctan\left(\frac{Y_j - y_i}{X_j - x_i}\right) - \theta_i \\ \vdots \end{pmatrix} - \begin{pmatrix} \bar{p}_{i-F+1} \\ \vdots \\ \bar{l}_j \\ \vdots \\ \bar{\theta}_i \\ \vdots \\ \bar{\alpha}_{ij} \\ \vdots \end{pmatrix} \quad (4)$$

$$= h(\mathbf{x}) - \mathbf{z} \quad (5)$$

mit

$$p_j \ominus p_i = \begin{pmatrix} \Delta x_{ij} \\ \Delta y_{ij} \\ \Delta \theta_{ij} \end{pmatrix} \quad (6)$$

$$= \begin{pmatrix} R^T(\theta_i) \left[\begin{pmatrix} x_j \\ y_j \end{pmatrix} - \begin{pmatrix} x_i \\ y_i \end{pmatrix} \right] \\ \theta_j - \theta_i \end{pmatrix} \quad (7)$$

wobei $R(\theta)$ die Rotationsmatrix um den Winkel θ bezeichnet.

Der gesuchte Zustandsvektor

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \|e(\mathbf{x})\|^2 \quad (8)$$

lässt sich durch den Levenberg-Marquardt Algorithmus ([5]) schätzen. Die hier verwendete Norm $\|\cdot\|$ ist eine Mahalanobis Norm, welche die entsprechenden Kovarianzmatrizen des Rauschens berücksichtigt. Anders als bei einem rekursiven Kalmanfilter wird die Odometrie nicht zum Prädizieren verwendet, sondern mit in die Messgleichung aufgenommen und als *Messung* interpretiert. Gleiches gilt für die unsicherheitsbehaftete Karte die ebenfalls als *Messung* interpretiert wird. Schätzergebnisse vergangener Zeitschritte bleiben (bis auf den Posenprior \bar{p}_{i-F+1}) im aktuellen Zeitschritt unberücksichtigt.

Quadratische Fehlerfunktionen wie in Gleichung (8) sind äusserst anfällig für grobe Fehlmessungen. Im ungünstigsten Fall kann ein einziger Ausreißer das gesamte Schätzergebnis beliebig stark verfälschen. Daher stellen wir im Folgenden eine robuste Version des oben skizzierten Schätzers vor.

Zu jedem Zeitschritt wird jede Landmarke einem Ausreißertest unterzogen. Es wird dabei die Hypothese getestet, ob der Teil des Residuenvektors $e(\mathbf{x})$, der zu der zu testenden Landmarke j gehört, einer Normalverteilung $\mathcal{N}(\cdot|0, \Sigma)$ folgt. Σ ist dabei eine blockdiagonale Messkovarianzmatrix für die Landmarke und Winkelmessungen. Die Landmarke j wirkt sich auf folgenden Teil des Residuenvektors aus:

$$r_j = \begin{pmatrix} l_j - \bar{l}_j \\ \vdots \\ \arctan\left(\frac{Y_j - y_i}{X_j - x_i}\right) - \theta_i - \bar{\alpha}_{ij} \\ \vdots \end{pmatrix} \in \mathbb{R}^D \quad (9)$$

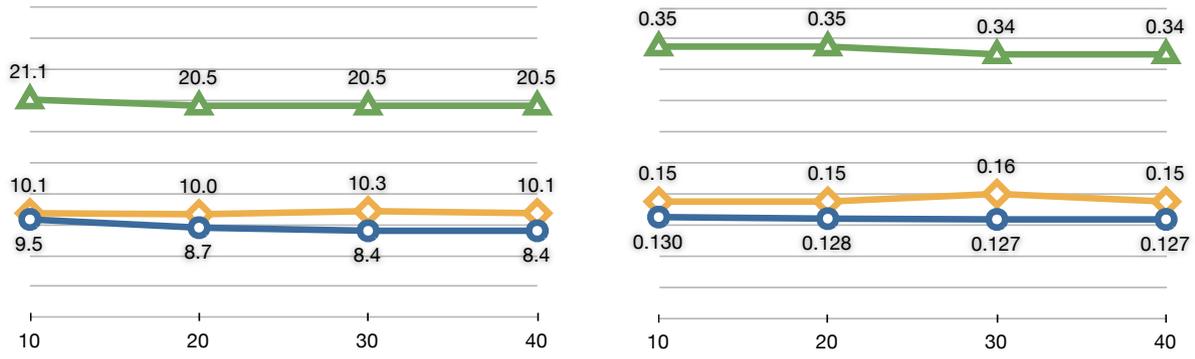


Abbildung 2: Simulationsergebnisse für variierende Fensterlängen F . Links: Positionsfehler in cm. Rechts: Winkelfehler in Grad. Gelb (Raute): Vorgestellte Methodik, Blau (Kreis): Vorgestellte Methodik ohne Ausreißer, Grün (Dreieck): Schätzverfahren mit implizit korrekter Karte (siehe Text für Details).

Es werden also alle Winkelmessungen die zu dieser Landmarke gehören, berücksichtigt. Der Landmarkenresiduenvektor r_j hat die Dimension D . Nun wird getestet, ob die Bedingung $r_j \sim \mathcal{N}(\cdot|0, \Sigma)$ erfüllt ist. Sollte sie nicht erfüllt sein, so handelt es sich um einen Ausreißer. Dazu wird ein χ^2 Test durchgeführt

$$r_j \sim \mathcal{N}(\cdot|0, \Sigma) \quad (10)$$

$$\Rightarrow r_j^T \Sigma^{-1} r_j \sim \chi_D^2(\cdot) \quad (11)$$

$$\Rightarrow \int_{r_j^T \Sigma^{-1} r_j}^{\infty} \chi_D^2(\theta) d\theta < \tau \quad (12)$$

wobei τ einen Schwellwert bezeichnet. Gilt die Bedingung (12), so wird die Landmarke l_j als Ausreißer behandelt. Andernfalls, wird sie als reguläre Landmarke angenommen. Im elementaren Unterschied zu einem Kalmanfilter kann ein Ausreißerhypothesentest innerhalb der Fensterlänge F revidiert werden, wenn neuere Messungen zusätzliche Evidenz liefern. Aus Effizienzgründen wird eine Landmarke, die nicht mehr im Sensorbereich liegt oder deren χ^2 -Wert sehr eindeutig war, nicht erneut getestet.

3 Simulationsexperimente

Nachfolgend werden die Schätzergebnisse aus einer Simulation vorgestellt. Die Landmarkenposition in der verfügbaren Karte sind dabei mit einer Standardunsicherheit von 10cm behaftet. 20% der Landmarken sind Ausreißer und mit einer Standardunsicherheit von 400cm versehen. Die Standardabweichung der Winkelmessungen ($\bar{\alpha}_{ij}$) beträgt 0.1 Grad.

Die durchschnittlichen Schätzfehler für Position (x, y) und Winkel (θ) sind in Abbildung 2 für variierende Fensterlängen F in gelb gezeigt. Die Schätzfehler für einen Simulationslauf, in der die Karte keine Ausreißer enthält, ist im Vergleich in blau dargestellt. Es zeigt sich hier nur eine marginale Verbesserung, was auf eine gute Ausreißerdetektion schließen lässt. Für ein Schätzverfahren, welches die Landmarkenposition nicht im Zustandsvektor mit aufnimmt (also $\mathbf{x} = (p_{i-F+1}, \dots, p_i)^T$), lassen sich die in grün dargestellten Ergebnisse erzielen. Dieses Schätzverfahren setzt implizit eine korrekte Karte voraus. Hier sind



Abbildung 3: Ein Bild aus der Zweitbefahrung (Lokalisierung). Detektierte Merkmalspunkte sind in rot dargestellt. Eine Zuordnung zu einer Landmarke wird durch einen grünen optischen Flussvektor repräsentiert.

die Fehler sowohl für Winkel als auch für Positionen deutlich höher. Für eine Lokalisierung mit unsicherheitsbehafteten Karten ist die Aufnahme der Landmarkenposition in den Zustandvektor somit sinnvoll und erzielt bessere Ergebnisse.

4 Experimente im Straßenverkehr

Im Folgenden präsentieren wir experimentelle Ergebnisse auf Messdaten aus einem überwiegend urbanen Umfeld. Zuerst wird kurz die Kartierung skizziert. Danach stellen wir das Ergebnis für eine Testfahrt vor.

Eine Teststrecke von 5,1 km wurde mit einer nach hinten gerichteten Stereokamera befahren. Die Kameradaten wurden zusammen mit hochgenauem DGPS aufgenommen. In einem Nachverarbeitungsschritt sind Merkmalspunkte im Kamerabild erkannt und zeitlich zugeordnet worden. Die Position der Landmarken, die zu diesen Merkmalspunkten gehören, konnten dann grob bestimmt werden.

Während einer Zweitbefahrung werden die zu den Landmarken gehörigen Merkmalspunkte den Merkmalspunkten des aktuellen Kamerabildes zugeordnet (vgl [3]). Die Assoziation geschieht hierbei durch eine visuelle Beschreibung der Punkte durch Merkmalsvektoren. Abbildung 3 zeigt eine solche Zuordnung. Merkmalspunkte sind in rot dargestellt. Eine Zuordnung zu Landmarken der Karte wird durch die grünen optischen Flussvektoren gekennzeichnet. Eine Initialpose wird per GPS bestimmt, um ein Matching im ersten Bild der Sequenz möglich zu machen. DGPS Messungen dieser Zweitbefahrung werden nachfolgend als Grundwahrheit angenommen, jedoch nicht für die Posenschätzung verwendet.

Werden alle Folgeposen durch Aufintegration der Odometriedaten bestimmt (Koppelnavigation), so driftet die Eigenpose unweigerlich. Ein solches Verhalten ist in Abbildung 4 gezeigt. Die geschätzte Trajektorie ist in blau und die Grundwahrheit ist in grün dargestellt. Es kann leicht erkannt werden wie der Eigenpositionsfehler über den Verlauf der Befahrung stetig wächst.

Abbildung 5 zeigt die Trajektorie, wie sie mit der vorgestellten Methode geschätzt werden kann. Die blauen (Schätzung) und grünen (Grundwahrheit) Posen überlagern sehr genau. Ausserdem ist der Positionsfehler driftfrei, d.h. unabhängig von der bereits gefahrenen Entfernung.

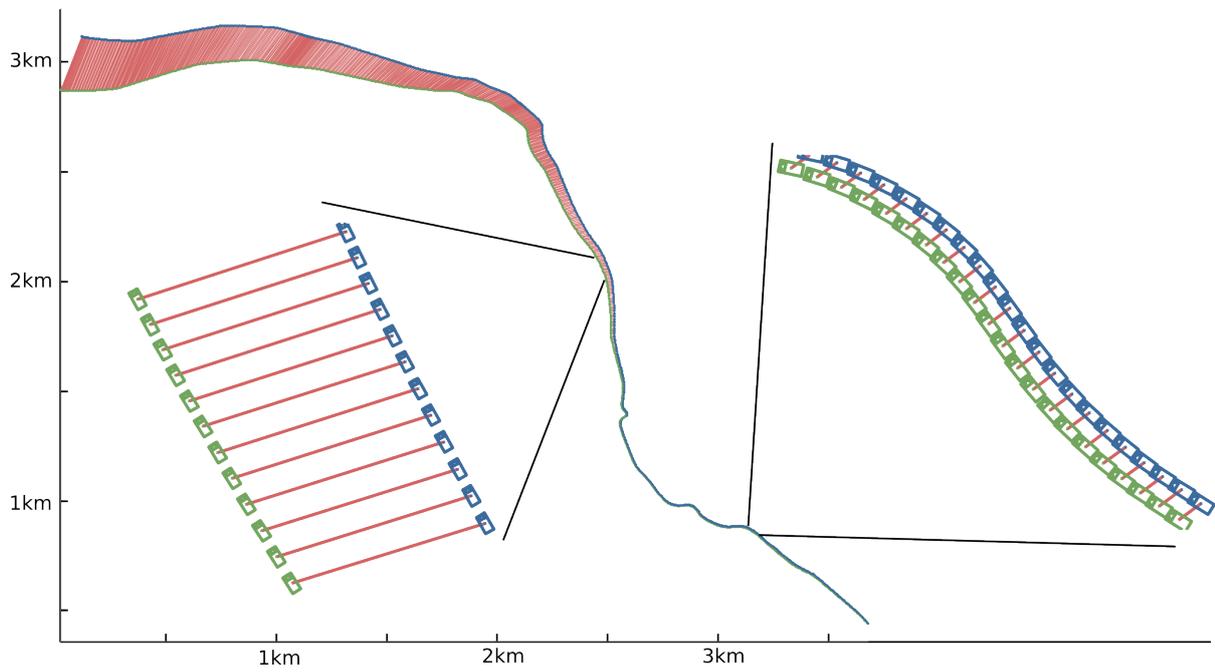


Abbildung 4: Geschätzte Trajektorie mittels Koppelnavigation. Grün: Grundwahrheit, Blau: Schätzung.

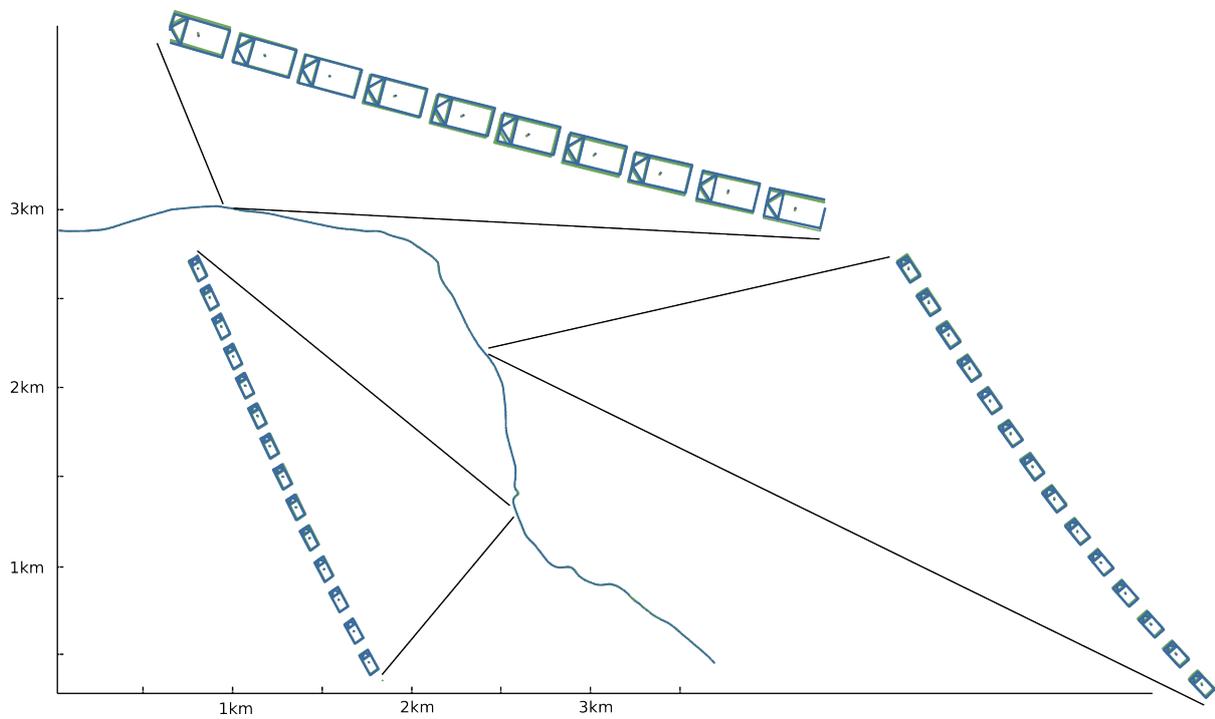


Abbildung 5: Geschätzte Trajektorie mit vorgestellter Methodik. Grün: Grundwahrheit, Blau: Schätzung.

5 Zusammenfassung und Ausblick

In diesem Beitrag wurde eine Methode zur landmarkenbasierten Lokalisierung vorgestellt. Eine Monokamera misst Winkel zu natürlichen Landmarken. Diese Winkelmessungen können dann mit Odometriemessungen kombiniert und eine Eigenpose bestimmt werden. Entscheidend ist dabei die Berücksichtigung der Unvollkommenheit der Landmarkenkarte. Man kann nicht erwarten, dass die Positionen der Landmarken exakt bekannt sind. Deshalb werden die Positionen der Landmarken, bei der vorgestellten Methode, mit geschätzt. Experimente zeigen eine dadurch verbesserte Lokalisierungsgenauigkeit. Des Weiteren wurde eine robuste Erweiterung einer nichtlinearer Ausgleichsrechnung mittels χ^2 Test erläutert. Landmarkenfehlmessungen können so erkannt und entsprechend behandelt werden.

Literatur

- [1] H. Badino, D. Huber, and T. Kanade. Visual topometric localization. In *Intelligent Vehicles Symposium (IV)*, Baden-Baden, Germany, June 2011.
- [2] A.J. Davison, I.D. Reid, N.D. Molton, and O. Stasse. MonoSLAM: Real-time single camera SLAM. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007.
- [3] A. Geiger, J. Ziegler, and C. Stiller. Stereoscan: Dense 3d reconstruction in real-time. In *Intelligent Vehicles Symposium (IV), 2011 IEEE*, pages 963–968. IEEE, 2011.
- [4] J. Levinson and S. Thrun. Robust vehicle localization in urban environments using probabilistic maps. In *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, pages 4372–4378. IEEE, 2010.
- [5] J. More. The Levenberg-Marquardt algorithm: implementation and theory. *Numerical analysis*, pages 105–116, 1978.
- [6] P. Piniés and J.D. Tardós. Large-scale slam building conditionally independent local maps: Application to monocular vision. *IEEE Transactions on Robotics*, 24(5):1094–1106, 2008.
- [7] O. Pink. Visual map matching and localization using a global feature map. In *Computer Vision and Pattern Recognition Workshops, 2008. CVPRW'08. IEEE Computer Society Conference on*, pages 1–7. IEEE, 2008.
- [8] Sebastian Rauch, Artim Savkin, Thomas Schaller, and Peter Hecker. Hochgenaue fahrzeugeigenlokalisierung und kollektives erlernen hochgenauer digitaler karten. In *AAET*, Braunschweig, Deutschland, 2012.