

Modellbasierte Erkennung von Regentropfen in Einzelbildern zur Verbesserung von videobasierten Fahrerassistenzfunktionen

Martin Roser* und Christoph Stiller*

Zusammenfassung: Dieser Beitrag präsentiert ein Verfahren zur modellbasierten Erkennung und Segmentierung von Regentropfen in Einzelbildern und zeigt Strategien zur Verbesserung bestehender Fahrerassistenzfunktionen bei Regen. Der Ansatz besteht aus einer Vorsegmentierung unscharfer Bildregionen und einer Bayes'schen Verifikation. Hierfür werden mit Hilfe eines optischen Brechungsmodells Regentropfenhypothesen generiert und für jede Bildregion die A-posteriori-Verteilung bezüglich unterschiedlicher, diskreter Tropfengrößen maximiert. Die A-priori-Verteilung wird durch ein empirisches Bayes Verfahren modelliert. Der vorgestellte Algorithmus erreicht selbst in schwierigen Testsequenzen eine Erkennungsrate von 50%. Fehldetektionen werden durch den vorgestellten Verifikationsschritt um eine Zehnerpotenz reduziert. Das Verbesserungspotenzial von modernen Fahrspurverfahren liegt bei 40 – 65%.

Schlüsselwörter: Regentropfenerkennung, Bayessche Klassifikation, Fahrerassistenz

1 Einleitung

Widrige Sichtverhältnisse stellen heutige Fahrerassistenzfunktionen vor enorme Herausforderungen. Insbesondere Regentropfen auf der Windschutzscheibe beeinträchtigen die videobasierte Wahrnehmung in erheblichem Maße und können zu unvorhergesehenem Verhalten, zu gesteigerten Fehlalarmraten oder sogar zum Totalausfall von sicherheitsrelevanten Applikationen führen. Heutige Regensensoren liefern nur eine globale Schätzung der Niederschlagsstärke und können funktions- und einbaulagenbedingt weder eine Bewertung der Bilddaten durchführen noch die Qualität von unterschiedlichen Bildbereichen evaluieren. Eine positionsgenaue Detektion und Segmentierung von Regentropfen auf der Windschutzscheibe von Automobilen lässt hingegen eine direkte und lokal differenzierte Qualitätsbewertung der Videodaten zu. Durch ausschließliche Nutzung der ungestörten Bildbereiche können Fehlmessungen reduziert und die Robustheit nachfolgender Fahrerassistenzapplikationen verbessert werden.

Trotz vieler Bemühungen in der Verkehrs- [3, 4, 12] und Sicherheitstechnik [10], bleibt das zuverlässige Erkennen von Regentropfen eine fordernde Aufgabe: Aufgrund ihrer variablen Formen und Größen sowie ihrer Transparenz können nur wenige aussagekräftige Merkmale für Regentropfen gefunden werden. Darüber hinaus reduziert die, aus der unzureichenden Schärfentiefe einer fokussierten Kamera resultierende Unschärfe des beobachteten Regentropfens seine Unterscheidbarkeit von der umgebenden Szene.

*Institut für Mess- und Regelungstechnik, Karlsruher Institut für Technologie (KIT), 76131 Karlsruhe, E-mail: {rosler,stiller}@kit.edu.

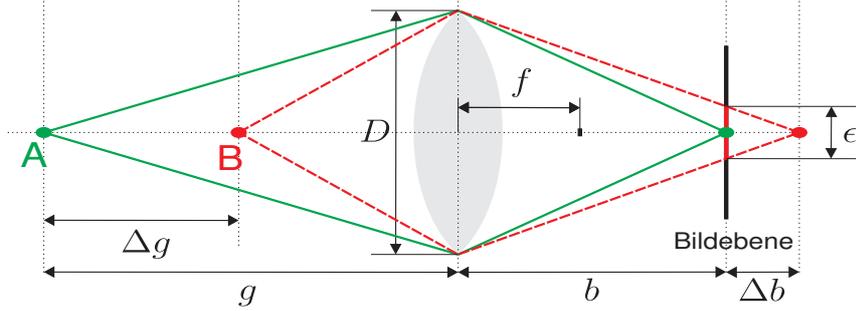


Abbildung 1: **Bestimmung von Unschärfe.** Punkt A wird scharf abgebildet, da er sich in der Gegenstandsweite g zur Linse befindet. Die Abbildung von Punkt B außerhalb des Schärfetiefenbereichs der Kamera erfolgt jedoch nicht mehr punktförmig, sondern als Unschärfescheibchen mit Durchmesser ϵ .

Kurihata et al. [4] detektierten Regentropfen anhand von gelernten Mustern, sogenannten *Eigentropfen*, die sie durch Hauptkomponentenanalyse auf den Grauwerten einer umfassenden Trainingsmenge gewannen. Das Verfahren eignet sich zur Detektion von Regentropfen in homogenen Bildbereichen. In höher strukturierten Gebieten repräsentieren die *Eigentropfen* allerdings nicht mehr das differenzierte Erscheinungsbild unterschiedlicher Tropfen. Yamashita et al. nutzten den optischen Fluss von gleichförmig schwenkbaren Überwachungskameras [10, 11] zur Detektion mitbewegter Regentropfen. Dieses Verfahren ist jedoch jenseits des Sonderfalls einer rein rotatorischen Bewegung nicht mehr invariant zur Entfernung der Szenenpunkte. Eine Anwendung im Automobil scheidet daher aus. Zhang et al. [12] kombinierten eine Wavelet-Transformation zur Segmentierung von unscharfen Bildbereichen mit einer Bewegungsanalyse mittels kumulativen Differenzbildern, um Verunreinigungen auf der Windschutzscheibe zu erkennen. Während opake Verunreinigungen zuverlässig erkannt werden, verursachen Regentropfen aufgrund ihrer hohen Transparenz Schwierigkeiten bei der Bewegungsanalyse.

Dieser Beitrag widmet sich der modellbasierten Erkennung und Segmentierung von Regentropfen in Einzelbildern. Zuerst erfolgt eine Auswahl markanter Bildregionen (ROIs), die sich außerhalb des Schärfbereichs der Kamera befinden (Kapitel 2). Mit Hilfe eines optischen Brechungsmodells (Kapitel 3) werden für diese ROIs Regentropfenhypothesen generiert und durch Bayes-Inferenz die Hypothese mit der maximalen A-posteriori-Wahrscheinlichkeit ausgewählt (Kapitel 4).

2 Merkmalsextraktion

Die Abbildungsgleichung der geometrischen Optik für dünne Linsen besagt, dass bei gegebener Brennweite f und Bildweite b nur diejenigen Objekte scharf abgebildet werden, die sich in der fokussierten Gegenstandsweite g zur Kameralinse befinden. Diese Annahme ist für Regentropfen im Nahbereich der Kamera nicht erfüllt. Aus Abb. 1 ergibt sich die Abbildungsgleichung für Objekte außerhalb des Schärfetiefenbereichs zu

$$\frac{1}{f} = \frac{1}{b + \Delta b} + \frac{1}{g - \Delta g}. \quad (1)$$

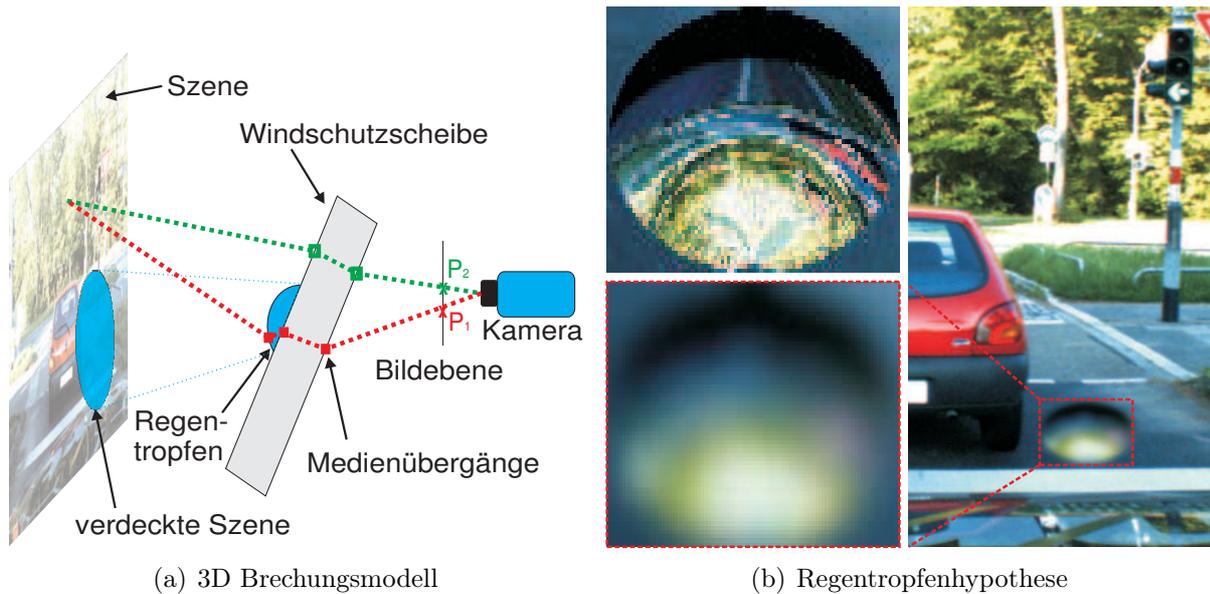


Abbildung 2: **Regentropfenmodell.** (a) illustriert den Strahlengang durch einen Regentropfen. (b) zeigt das Ergebnis des Raytracing Prozesses (links oben) und die Regentropfenhypothese (links unten), die sich durch Faltung mit einem Unschärfescheibchen des Durchmessers ϵ ergibt.

Aus geometrischen Beziehungen folgt für den Durchmesser des Unschärfescheibchens ϵ

$$\epsilon = \frac{\Delta g f^2}{O(g - \Delta g)(g - f)}, \quad (2)$$

wobei $O = \frac{f}{D}$ die gewählte Blende bezeichnet. Die Unschärfe ist allein abhängig von den gegebenen Kameraparametern und der relativen Einbaulage der Kamera zur Windschutzscheibe. Sie bildet damit ein markantes Merkmal zur Detektion von Regentropfen.

Das Frequenzband wird mittels eines DoG (engl. *Difference of Gaussian*) Filters extrahiert. Es ist variabel mit der Bildposition, da sich der Abstand zwischen dem Brennpunkt der Kamera und der Windschutzscheibe mit der Bildposition ändert. Die Vorsegmentierung markanter ROIs $\mathbf{z} = (u, v, r)^T$ mit Mittelpunkt u, v und Radius r erfolgt abschließend durch einen Regionendetektor, wie z.B. SURF [1] im DoG-gefilterten Bild.

3 Modellbildung

Zur Validierung der segmentierten ROIs wird in diesem Kapitel die modellgestützte Generierung von Regentropfenhypothesen $\mathbf{D}_1, \dots, \mathbf{D}_n$ für verschiedene Tropfenvolumen vorgestellt. Für die Zurückweisung von ROIs wird darüber hinaus eine Hypothese \mathbf{D}_0 benötigt, die den Tropfenhintergrund, also die verdeckte Szene in Abb. 2a modelliert. Hierzu wird ein Standardverfahren zur Bildwiederherstellung (engl. *Image Inpainting*) [7] genutzt.

3.1 Geometrisches Regentropfenmodell

Wie in Abb. 2a illustriert, wird der Sichtstrahl eines Szenenpunktes beim Durchwandern von Regentropfen und Windschutzscheibe mehrfach gebrochen, bevor ihn die Kamera in

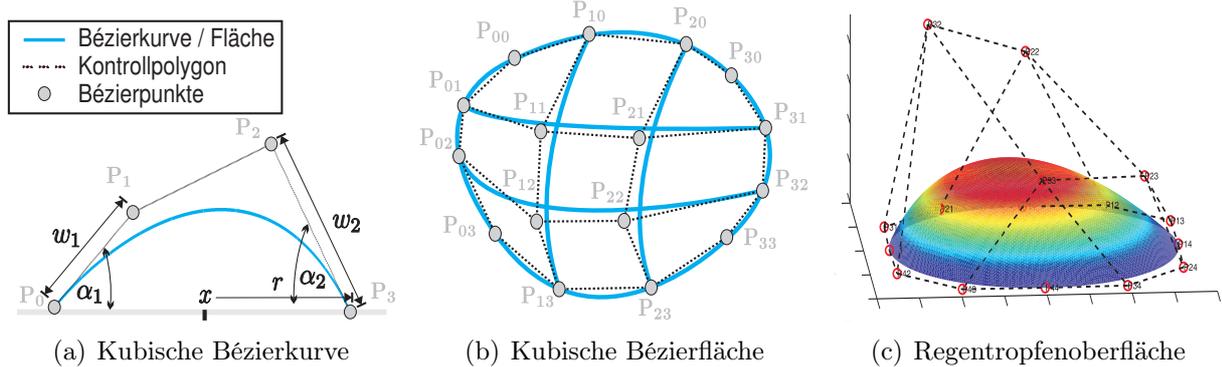


Abbildung 3: **Kubische Bézierkurve und -flächen.** Eine Kurve ist gegeben durch 4 Bézierpunkte und liegt innerhalb der konvexen Hülle des Kontrollpolygons (a). Zur Approximation gekrümmter Flächen werden 16 Bézierpunkte benötigt (b). (c) zeigt die berechnete Tropfenoberfläche für einen Regentropfen mit Volumen $20\mu\text{l}$ und Windschutzscheiben Neigungswinkel 25° .

Punkt \mathbf{P}_1 sensiert. Solange keine Verdeckung des Szenenpunktes vorliegt, existiert ein Bildpunkt \mathbf{P}_2 , der den identischen Szenenpunkt abbildet. Bei gegebenen Kameraparametern, relativer Einbaulage der Kamera zur Windschutzscheibe und Parametrierung der Regentropfenoberfläche ist diese Punktkorrespondenz durch die geometrischen Brechungsgesetze gegeben [3]. Abb. 2b zeigt die Komposition einer Regentropfenhypothese aus der Menge aller Punktkorrespondenzen \mathbf{P}_2 für eine beliebige ROI.

3.2 Parametrierung der Tropfenoberfläche

Die Parametrierung der Regentropfenoberfläche \mathbf{S} spielt eine wichtige Rolle, da jeder Sichtstrahl je nach Oberflächennormalenfeld $\nabla\mathbf{S}$ unterschiedlich gebrochen wird. Unter Vernachlässigung von Gravitation können Regentropfen ausreichend genau als Kugelkappen mit Radius R und Kontaktwinkel α modelliert werden [3]. Die Schwerkraft verursacht jedoch eine Verschiebung der Tropfenmasse in Richtung der geneigten Windschutzscheibe und führt zu einem bauchigen Erscheinungsbild des Tropfens.

Bézierflächen ermöglichen variabel gekrümmte Oberflächen mit wenigen und physikalisch interpretierbaren Parametern zu beschreiben. Zunächst soll auf den eindimensionalen Fall einer Bézierkurve eingegangen werden: Eine Bézierkurve n -ten Grades ist gegeben durch $n + 1$ Bézier Punkte $(\mathbf{P}_i)_{i=0}^n$, $\mathbf{P} \in \mathbb{R}^2$ und wird mit der Bogenlänge $t \in [0 \dots 1]$ parametrisiert

$$\mathbf{S}(t) = \sum_{i=0}^n \mathbf{B}_{i,n}(t) \mathbf{P}_i, \quad (3)$$

wobei das Bernstein Polynom i des n -ten Grades [2] beschrieben wird durch:

$$\mathbf{B}_{i,n}(t) = \binom{n}{i} t^i (1-t)^{n-i}. \quad (4)$$

Fordert man einen Kontakt der Randpunkte mit der Windschutzscheibe, bleiben wie in Abb. 3a gezeigt 6 freie Parameter zur Beschreibung eines Regentropfens: x bezeichnet den Tropfenmittelpunkt auf der Scheibe, r den Radius, α_1, α_2 die Kontaktwinkel und

w_1, w_2 die Bézier Gewichtungsfaktoren. Die Parameter $\alpha_1, \alpha_2, w_1, w_2$ hängen allein von der Neigung der Windschutzscheibe ab [5], während x durch die Vorsegmentierung aus Kapitel 2 zuverlässig bestimmt werden kann. Es bleibt der Radius r als einzig freier Parameter übrig. Bézierflächen (Abb. 3b) berechnen sich analog zum eindimensionalen Fall zu

$$\mathbf{S}(s, t) = \sum_{i=0}^n \sum_{j=0}^m \mathbf{B}_{i,n}(s) \mathbf{B}_{j,m}(t) \mathbf{P}_i, \quad \mathbf{P} \in \mathbb{R}^3 \quad (5)$$

wobei $\mathbf{B}_{i,n}(s)$ und $\mathbf{B}_{j,m}(t)$ die Bernsteinpolynome gemäß (4) bezeichnen. Das Kreuzprodukt aus den beiden partiellen Ableitungen in s und t -Richtung bildet das gesuchte Oberflächennormalenfeld $\nabla \mathbf{S}$. Durch Annahme einer kreisförmigen Kontaktfläche auf der Windschutzscheibe können alle Freiheitsgrade bis auf einen Parameter, das Tropfenvolumen V , reduziert werden (siehe Abb. 3c).

4 Bayes-Inferenz

Im vorherigen Kapitel wurde die Generierung von Regentropfenhypothesen \mathbf{D}_i für verschiedene diskrete Tropfenvolumen $V_i, i \in [1, \dots, n]$. Bei dem Erkennungsschritt gilt es nun, die beste Hypothese in einer Klasse von Hypothesen zu finden. Dies kann durch Maximierung der A-posteriori-Verteilung bezüglich des freien Parameters, hier des Tropfenvolumens, erzielt werden.

4.1 Maximum-A-Posteriori Schätzung

Die Regentropfenerkennung erfolgt durch Auswahl derjenigen Hypothese mit der maximalen A-posteriori-Wahrscheinlichkeit:

$$\arg \max_i (p(\mathbf{D}_i | \mathbf{z})) = \arg \max_i (p(\mathbf{D}_i) p(\mathbf{z} | \mathbf{D}_i)), \quad i \in [0, \dots, n] \quad (6)$$

wobei $\mathbf{z}(u, v, r)$ die ROI an Bildposition u, v mit Radius r aus Kapitel 2 repräsentiert. Wird für eine ROI eine Regentropfenhypothese $\mathbf{D}_1 \dots \mathbf{D}_n$ gewählt, so gilt die Bildregion als verifiziert. Fällt die Wahl jedoch auf die Hintergrundhypothese \mathbf{D}_0 , so wird die ROI zurückgewiesen.

4.2 Likelihood-Funktion

Als Gütemaß zur Suche von Bildkorrespondenzen werden üblicherweise summierte Residuen, wie z.B. SAD (engl. *Sum-of-Absolute Differences*) oder SSD (engl. *Sum-of-Squared Differences*) verwendet. Für diese Anwendung bietet sich jedoch eine Fehlerfunktion basierend auf dem Korrelationskoeffizienten an, da er bei zwei gegebenen Bildregionen I, J mit jeweils N Bildpunkten invariant zum mittleren Grauwert \bar{I}, \bar{J} und der Varianz σ_I^2, σ_J^2 der Bildregionen ist.

$$\rho(I, J) = \frac{1}{N \sigma_I \sigma_J} \sum_{i=1}^N (I_i - \bar{I})(J_i - \bar{J}). \quad (7)$$

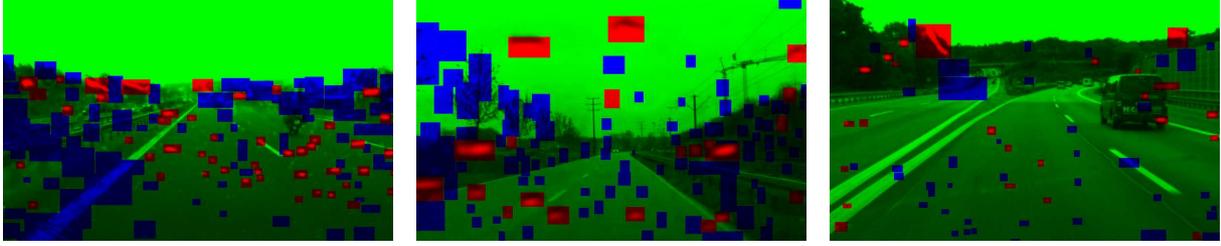


Abbildung 4: **Groundtruth.** Manuelle Segmentierung in die Klassen *Regentropfen* (rot), *Hintergrund* (grün), *Unbekannt* (blau) für unterschiedliche Kameraeinbaugeometrien.

Damit kann als Likelihood-Funktion

$$p(\mathbf{z}|\mathbf{D}) \propto e^{2(\rho(I,J)-1)} \quad (8)$$

gewählt werden.

4.3 Wahl der A-Priori-Verteilung

Die unbekannt Parameter der A-priori-Verteilung werden mit Hilfe eines empirischen Bayes-Verfahrens direkt aus den Daten geschätzt und daraus die diskreten Existenzwahrscheinlichkeiten der jeweiligen Hypothesen gezogen. Dadurch kann auf wechselnde Umgebungsbedingungen und Niederschlagsintensitäten eingegangen werden [8].

Dieser Beitrag modelliert unterschiedliche A-priori-Wahrscheinlichkeiten für Regentropfen- und Hintergrundhypothesen (Tabelle 1) auf Grundlage einer Wetterklassifikation in Einzelbildern [6]. Die Existenzwahrscheinlichkeit von Hypothesen mit unterschiedlichen Tropfenvolumen $p(\mathbf{D}_1)..p(\mathbf{D}_6)$ werden als gleichverteilt angenommen.

Tabelle 1: Modellierung der A-priori-Verteilung.

Niederschlag	$p(\mathbf{D}_0)$	$p(\mathbf{D}_1)..p(\mathbf{D}_6)$
leicht	0.25	0.125
mittel	0.22	0.13
stark	0.2	0.133

5 Experimentelle Ergebnisse

5.1 Bewertungskriterium

Zur Evaluation werden 5 Sequenzen (1346 Einzelbildern) mit unterschiedlicher Regenstärke und verschiedenen Einbaugeometrien der Kamera verwendet und manuell in die Klassen $K = \{\textit{Regentropfen}, \textit{Hintergrund}, \textit{Unbekannt}\}$ segmentiert (siehe Abb. 4). Insgesamt wurden 24627 Regionen der Klasse *Regentropfen* zugewiesen.

Eine korrekte Erkennung des Regentropfens (engl. $TP = \textit{true positive}$) liegt vor, wenn sich der Mittelpunkt einer verifizierten ROI innerhalb eines Segments der Klasse *Regentropfen* befindet. Liegt der Mittelpunkt einer verifizierten ROI innerhalb der

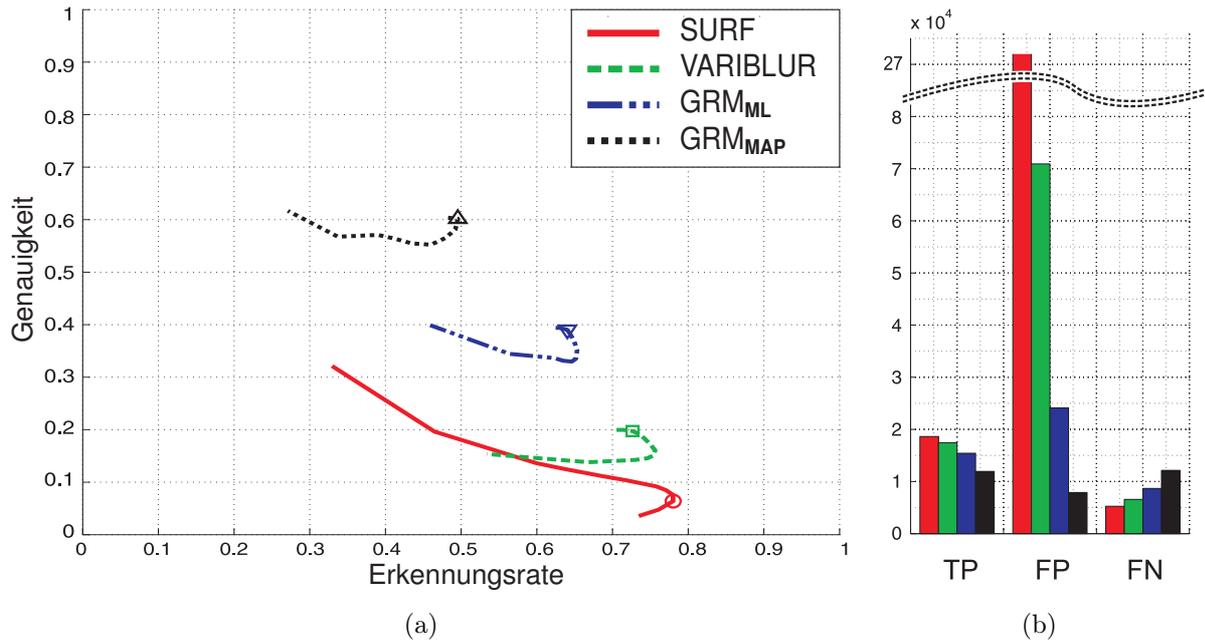


Abbildung 5: **Ergebnisse der Regentropfenerkennung.** (a) zeigt Erkennungsrate und Genauigkeit von ausgewählten Detektionsalgorithmen bei Variation des Detektionsschwellwertes. Für die jeweils besten Schwellwerte sind die Kennzahlen TP, FP und FN in (b) gegeben.

Hintergrund-Klasse, zählt die ROI als falsch erkannt (engl. *FP = false positive*). Alle Segmente der Klasse *Regentropfen*, die nicht gefunden wurden, zählen als nicht erkannt (engl. *FN = false negative*). Die Klasse *Unbekannt* beinhaltet alle Pixel, die selbst von Menschen nicht eindeutig zugeordnet werden können. Sie werden für die nachfolgende Untersuchung der Erkennungsrate nicht berücksichtigt.

5.2 Erkennungsrate

Die Evaluation der Regentropfenerkennung erfolgt wie in Abb. 5a gezeigt mit Hilfe der Kennwerte *Genauigkeit* und *Erkennungsrate* (engl. *Precision-Recall*):

$$\text{Genauigkeit} = \frac{TP}{TP + FP}, \quad \text{Erkennungsrate} = \frac{TP}{TP + FN} \quad (9)$$

Als Basis dient eine einfache ROI Detektion mit einem *SURF* Detektor [1]. Wie aus Abb. 5a ersichtlich, können bei geringen Schwellwerten bis zu 18625 Regentropfen erkannt werden (Erkennungsrate 78.02%), allerdings zu Lasten einer sehr niedrigen Genauigkeit (6.4%). Mit der Vorsegmentierung aus Kapitel 2 (*VARIBLUR*) wird hingegen eine vergleichbar hohe Erkennungsrate von 72.64% erreicht (17443 TP), die Genauigkeit jedoch auf 19.74% gesteigert. Das verdeutlicht die Signifikanz des Merkmals „Unschärfe“ im Vergleich zu Kontrastmerkmalen für die Aufgabe der Regentropfenerkennung. Trotzdem beinhalten viele kontrastreiche Hintergrundregionen ebenfalls das interessierende Frequenzband, wodurch dieses Verfahrens eine Genauigkeit von maximal 20% erreicht.

Zur weiteren Verbesserung der Regentropfenerkennung wurden mit Hilfe des geometrischen Regentropfenmodells (*GRM*) 6 Tropfenhypthesen mit einem Volumen von $1 - 20 \mu\text{l}$

erzeugt und die Detektionsergebnisse aus *VARIBLUR* durch eine MAP Schätzung verifiziert. Bei GRM_{ML} wurde das Vorwissen als Gleichverteilung modelliert, was in einer Maximum-Likelihood Entscheidung für die beste Hypothese resultiert. In GRM_{MAP} wurde die A-priori-Verteilung aus Tabelle 1 verwendet.

Durch eine Verifikation der Regentropfen GRM_{ML} konnte die Anzahl an Fehldetektionen von 70915 auf 24110 deutlich reduziert werden und nur 2014 in *VARIBLUR* erkannte Regentropfen wurden im Verifikationsschritt verworfen (*VARIBLUR*: 17443 TP, GRM_{ML} : 15429). Das ergibt eine Erkennungsrate von 64.03% und eine Genauigkeit von 39.02%. Eine Bevorzugung der Hintergrundhypothese durch GRM_{MAP} führt zu einer weiteren Steigerung der Genauigkeit (60.18%) bei gleichzeitiger Minderung der Erkennungsrate (49.56%). Im Vergleich zu *VARIBLUR* konnten die Fehldetektionen um 88.86% auf 7898 reduziert werden, wogegen nur 31.56% der korrekt erkannten Regentropfen verworfen wurden. Auch im Vergleich zu GRM_{ML} zeigt sich die Modellierung des Vorwissens mit Hilfe des empirischen Bayes Verfahrens als überlegen.

5.3 Anwendungsbeispiel: Fahrspurerkennung

In diesem Kapitel wird das Verbesserungspotenzial von existierenden Fahrerassistenzsystemen am Beispiel einer videobasierten Fahrspurerkennung (siehe [9], Kapitel 15.5.1) gezeigt. Das Verfahren beruht auf der Extraktion von Markierungskandidaten durch Korrelation des Bildsignals mit einem Template, dessen Breite an die Entfernung der Fahrbahnebene zur Kamera angepasst wird. Um Effekte verschieden robuster Schätzverfahren auszuschließen, erfolgt der Vergleich auf Merkmalsebene in Einzelbildern. Hierfür werden Beobachtungen an 49 Stützstellen in einer Entfernung von 6 – 30m vor dem Fahrzeug gewonnen und ein Polynom 2. Grades nach der Methode der kleinsten Fehlerquadrate geschätzt.

Regentropfen können starke Kontraste aufweisen und Beobachtungen verursachen, die nicht auf einer Fahrspur liegen (Ausreißer). Je nach Robustheit des Schätzverfahrens und Verteilung der Regentropfen im Bild kann dies zum Versagen einer konventionellen Fahrspurerkennung führen. Eine Strategie zur Verbesserung der Fahrspurerkennung ist die vorherige Anwendung des vorgestellten Verfahrens zur Regentropfenerkennung und Maskierung aller gestörten Bildbereiche.

Abb. 6a zeigt die Modellgüte als normiertes Histogramm der Residuen zwischen Beobachtung und geschätztem Fahrspurmodell. Unter der Annahme, dass die Fahrspur durch ein Polynom 2. Grades hinreichend genau beschrieben wird, Regentropfen dieses Modell jedoch i.A. verletzen, ermöglicht dies eine Einschätzung, wie gut das gewählte Modell die Beobachtungen beschreibt. Dieses Bewertungsprinzip wurde gewählt, um Fehler in der manuell markierten Groundtruth auszuschließen. Wie in Abb. 6a gezeigt wird die Ausreißerquote von 23% bei einer konventionellen Fahrspurerkennung (blau) durch vorgestellte Regentropfenerkennung auf 15% (grün) reduziert. Eine ideale Erkennung der Regentropfen (manuell erstellte Groundtruth, rot) würde eine Minderung der Ausreißerquote auf unter 5% ermöglichen.

Desweiteren wurde die mittlere Messabweichung (Abb. 6b) in Abhängigkeit der gestörten Bildfläche betrachtet. Bei einer konventionellen Fahrspurerkennung nimmt der mittlere Fehler deutlich zu, je mehr Regentropfen das Bild stören (blau). Dieser Effekt kann durch eine Maskierung der erkannten Regentropfen um bis zu 40% reduziert werden (grün). Eine Maskierung mit Hilfe der Regentropfen Groundtruth zeigt eine fast

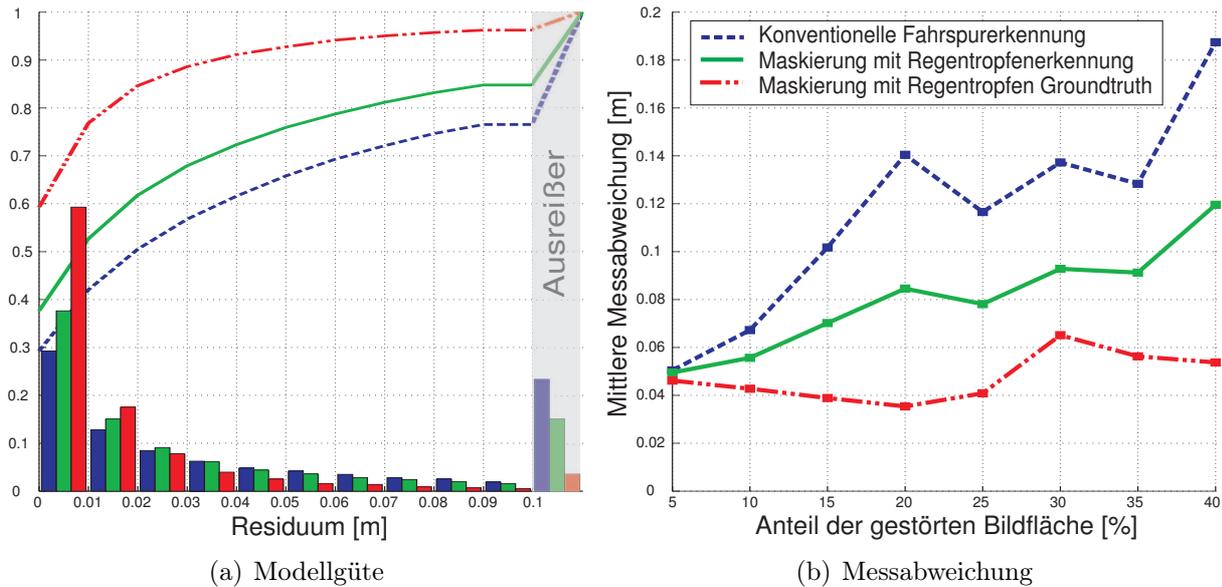


Abbildung 6: **Qualitätsbewertung Fahrspurerkennung.** Das normierte Histogramm in (a) zeigt die Modellgüte einer konventionellen Fahrspurerkennung (blau), in Kombination mit der vorgestellten Regentropfenerkennung (grün) und in Kombination mit der idealen Regentropfen Groundtruth (rot). Die farbigen Kurven repräsentieren die entsprechenden, summierten Histogramme. (b) zeigt den mittleren Fehler zwischen den Beobachtungen und der Groundtruth über dem prozentualen Anteil der gestörten Bildfläche.

ausreißerfreie Fahrspurerkennung mit annähernd konstantem mittleren Fehler (rot). Die Verbesserung zur konventionellen Fahrspurerkennung beträgt bis zu 65%.

6 Zusammenfassung und Ausblick

Es wurde ein Verfahren zur Segmentierung von Regentropfen in Einzelbildern vorgestellt. Mit Hilfe einer Bayes'schen Verifikation von markanten Bildregionen konnten 88.86% aller Fehldetektionen eliminiert werden. Das vorgestellte Verfahren erkennt in repräsentativen, schwierigen Testsequenzen 50% aller Regentropfen bei einer Genauigkeit von 60%. Die Ergebnisse verdeutlichen, dass keine Notwendigkeit einer vollständigen Erkennung aller Regentropfen besteht. Es wurde gezeigt, dass selbst bei diesen Erkennungsraten konventionelle Fahrspurerkennungen um bis zu 40% verbessert werden können. Bei Erhöhung der Erkennungsrate von Regentropfen existiert ein deutliches Verbesserungspotenzial für konventionelle Fahrspurerkennungen von bis zu 65%.

Zukünftige Schwerpunkte bestehen in einer genauen Modellierung der A-priori-Verteilung für verschiedene Regentropfengrößen mit Hilfe von empirischen Bayes Verfahren. Darüber hinaus bietet das zeitliche Verfolgen von Regentropfen auf der Windschutzscheibe eine Möglichkeit zur gleichzeitigen Steigerung von Erkennungsrate und Genauigkeit.

Literatur

- [1] Herbert Bay, Tinne Tuytelaars, and Luc Van Gool. Surf: Speeded up robust features. In *European Conference on Computer Vision (ECCV '06)*, Graz Austria, May 2006.
- [2] Gerald E. Farin. *Curves and surfaces for CAD: a practical guide*. The Morgan Kaufmann series in computer graphics and geometric modeling. Morgan Kaufmann, San Francisco [u.a.], 5. edition, 2002.
- [3] Jad Halimeh and Martin Roser. Raindrop detection on car windshields using geometric-photometric environment construction and intensity-based correlation. In *IEEE Intelligent Vehicle Symposium (IV '09)*, Xi'an, China, 2009.
- [4] H. Kurihata, T. Takahashi, I. Ide, Y. Mekade, H. Murase and Y. Tamatsu, and T. Miyahara. Rainy weather recognition from in-vehicle camera images for driver assistance. In *IEEE Intelligent Vehicles Symposium (IV '05)*, pages 205–210, 2005.
- [5] Martin Roser, Julian Kurz, and Andreas Geiger. Realistic modeling of water droplets for monocular adherent raindrop recognition using bézier curves. In *Asian Conference on Computer Vision (ACCV '10)*, Queensland, New Zealand, 2010.
- [6] Martin Roser and Frank Moosmann. Classification of weather situations on single color images. In *IEEE Intelligent Vehicle Symposium (IV '08)*, Eindhoven, Netherlands, 2008.
- [7] Alexandru Telea. An image inpainting technique based on the fast marching method. *Journal of Graphics, GPU, and Game Tools*, 9(1):23–34, 2004.
- [8] Nuno Vasconcelos and Andrew Lippman. Empirical bayesian em-based motion segmentation. In *IEEE Conference on Computer Vision and Pattern Recognition (CV-PR '97)*, pages 527–532, Puerto Rico, 1997.
- [9] Hermann Winner, Stephan Hakuli, and Gabriele Wolf. *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Vieweg + Teubner, 1. edition, Juli 2009.
- [10] A. Yamashita, I. Fukuchi, T. Kaneko, and K.T. Miura. Removal of adherent noises from image sequences by spatio-temporal image processing. In *IEEE International Conference on Robotics and Automation (ICRA '08)*, 2008.
- [11] A. Yamashita, T. Harada, T. Kaneko, and K.T. Miura. Removal of adherent noises from images of dynamic scenes by using a pan-tilt camera. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '04)*, 2004.
- [12] Yi Zhang, Jie Yang, Kun Liu, and Xiang Zhang. Self-detection of optical contamination or occlusion in vehicle vision systems. *Journal of Optical Engineering*, 47(6):067006, 2008.