


**Neuronale Dynamik zur multispektralen  
Sensorfusion:  
Quantifizierung von Ölschichten auf  
Meeresoberflächen**



Diplomarbeit von

Kay Gorontzi

30. Oktober 1998

**Institut für Neuroinformatik**  
Lehrstuhl für theoretische Biologie  
Prof. Dr.-Ing. W. v. Seelen

**Fakultät für Elektrotechnik**  
Lehrstuhl für Datenverarbeitung  
Prof. Dr.-Ing. W. Weber

Betreuung durch Dr. A. Steinhage und Dipl.-Ing. C. Winkel

## Zusammenfassung

In der vorliegenden Arbeit werden Instantiierte Neuronale Felder (INF) als ein neues Verfahren zur Lösung von Sensorfusionsproblemen vorgestellt. Der Ansatz beruht auf der Verwendung einer neuronalen Dynamik, mit der sich die Meßwerte verschiedener Einzelsensoren jeweils zu einem Gesamtwert fusionieren lassen. Das INF kann dabei sog. *Ausreißer* selbständig erkennen und aus der Berechnung eliminieren. Hierbei werden sogar Totalausfälle detektiert und entsprechend berücksichtigt. Weiterhin erlauben INFs auch die im Signal enthaltenen Rauschanteile stark zu reduzieren und die Meßwerte zu glätten.

Auf synthetischen Daten wird zunächst gezeigt, daß man die Komplexität eines INFs in Abhängigkeit von den Anforderungen modular erhöhen kann. Durch das schrittweise Hinzufügen einzelner, sogenannter Iterationsterme kann das Verhalten des INFs an die jeweils vorliegenden Störungsverhältnisse angepaßt werden. INFs bieten somit ein sehr konstruktives Verfahren zum Aufbau einer sensorfusionierenden Meßdatenverarbeitung, in die Vorwissen gut eingebracht werden kann.

Die wählbaren Parameter des INFs werden in ihrer Funktion beschrieben und qualitativ anhand ihrer Wirkung auf simulierte Testdaten untersucht. Hieraus ergeben sich einige einfache Anhaltspunkte zur Parameterwahl.

Die Leistung des INFs bei der Meßdatenverarbeitung wird anschließend an einem multispektralen Sensorfusionsproblem demonstriert. Es liegen hierzu Messungen von Ölfilmen auf einer Meeresoberfläche vor, die parallel mit mehreren Radiometern unterschiedlicher Frequenzbereiche aufgenommen wurden. Das vorgestellte Anwendungsfeld ist Teil eines ökologischen Meeresüberwachungssystems zur Vermeidung von Umweltschäden durch Öleinleitung.

*Meinen Eltern gewidmet*

## Inhaltsverzeichnis

<b>1</b>	<b>Einleitung, Motivation der Arbeit</b>	<b>1</b>
<b>2</b>	<b>Grundlagen der Vermessung von Ölflecken</b>	<b>2</b>
2.1	Verwendung von Mikrowellen . . . . .	2
2.2	Planck'sche Wärmestrahlung . . . . .	3
2.3	Radiometer . . . . .	4
2.4	Signalqualität, prinzipielle Wahl der Frequenzen . . . . .	6
2.5	Modellkonforme Wahl der Meßfrequenzen . . . . .	11
<b>3</b>	<b>Erzeugung synthetischer Testdaten</b>	<b>12</b>
3.1	Programmtechnische Erzeugung der Testdaten . . . . .	14
3.2	Typen von Ölverteilungen . . . . .	15
3.3	Simulation von Störungen . . . . .	18
3.3.1	Abtastung mit virtuellen Antennen . . . . .	19
3.3.2	Offsetfehler . . . . .	25
3.3.3	Kanalrauschen . . . . .	26
3.3.4	Spikes . . . . .	26
3.3.5	Ausreißer . . . . .	27
3.3.6	Sättigung . . . . .	28
3.3.7	Totalausfälle . . . . .	28
3.4	Zusammenfassung der Störungsparameter . . . . .	29
<b>4</b>	<b>Sensorfusion mit Neuronalen Feldern</b>	<b>31</b>
4.1	Grundlagen . . . . .	31
4.1.1	Sensorfusion . . . . .	31

---

4.1.2	Neuronale Felder . . . . .	32
4.1.3	Konvergenzbegriff . . . . .	34
4.1.4	Gewichtete Mittelwerte . . . . .	34
4.2	Instantiierte Neuronale Felder (INF) . . . . .	37
4.3	Metrik zur Bewertung eines INF' . . . . .	41
4.4	Eliminierung von "Ausreißern" . . . . .	44
4.4.1	Einführung einer neuronalen Dynamik . . . . .	47
4.4.2	Sensorfusion ohne Nachbarschafts-Wechselwirkung . . . . .	50
4.5	Gewichtung der Meßkanäle mit Vertrauensfaktoren . . . . .	53
4.6	INF mit Ortswechselwirkungen . . . . .	57
4.6.1	Prinzip . . . . .	57
4.6.2	Realisierung als Iterationsterm . . . . .	58
4.6.3	Erweiterung der Iterationsregel . . . . .	60
4.6.4	Anmerkungen zur programmtechnischen Realisierung in IDL . . . . .	62
4.6.5	Experimente: Sensorfusion mit Wechselwirkungen . . . . .	64
4.6.6	Iteration und Konvergenz . . . . .	68
<b>5</b>	<b>Diskussion der Parameter</b>	<b>73</b>
5.1	Einfluß der Zeitskalierung . . . . .	74
5.2	Einfluß der Attraktorreichweiten . . . . .	77
5.3	Gewichtung der Iterationsterme: $\eta_A$ und $\eta_N$ . . . . .	82
5.4	Einfluß der Startwerte . . . . .	86
5.5	Einfluß des Nachbarschafts-Radius . . . . .	92
<b>6</b>	<b>Untersuchung realer Meßdaten</b>	<b>98</b>
6.1	Rauschsignale . . . . .	99

---


6.2	Gewinnung der Daten, Meßaufbau . . . . .	100
6.2.1	Ortstreue der Meßwerte . . . . .	101
6.2.2	Spezielle Probleme der vorliegenden Meßdaten . . . . .	104
6.2.3	Modellwahl . . . . .	104
6.3	Vorverarbeitung . . . . .	106
6.3.1	Offset-Korrektur . . . . .	108
6.3.2	Winkelabhängigkeit . . . . .	111
6.4	Ergebnisse der INF-Verarbeitung . . . . .	113
6.5	Erweiterungsmöglichkeiten . . . . .	120
6.5.1	Korrektur von Mehrdeutigkeiten . . . . .	120
6.5.2	Laterale Inhibition im INF . . . . .	123
6.5.3	Hinzunahme weiterer Meßdatenquellen . . . . .	123
6.6	Vergleiche mit anderen Verfahren . . . . .	124
6.6.1	Einfache Mittelung . . . . .	124
6.6.2	Neuronale Netze . . . . .	124
<b>7</b>	<b>Zusammenfassung</b>	<b>126</b>
<b>8</b>	<b>Ergebnisse</b>	<b>127</b>
<b>9</b>	<b>Ausblick</b>	<b>129</b>
<b>A</b>	<b>Nomenklatur</b>	<b>131</b>
<b>B</b>	<b>Elektrischer Aufbau der Meßkanäle</b>	<b>133</b>
<b>C</b>	<b>INF Simulationsprogramm</b>	<b>134</b>
<b>D</b>	<b>Programm Synth</b>	<b>141</b>

## 1 Einleitung, Motivation der Arbeit

Die vorliegende Arbeit beschäftigt sich mit dem Problem der Sensorfusion. Bei der Erfassung von Meßdaten stehen oft für eine Meßgröße mehrere Meßwerte auf verschiedenen – mehr oder weniger redundanten – Kanälen zur Verfügung. Im vorliegenden Fall handelt es sich um passive Radiometermessungen von Ölschichten auf Meeresoberflächen.

Die Messung erfolgte in einer Höhe von rund 300 Metern vom Flugzeug aus. Die Meßdaten wurden mit mehreren Antennen bei verschiedenen festen Frequenzen aufgenommen. Das Problem besteht nunmehr darin, aus den Temperaturmessungen der einzelnen Antennen auf die tatsächliche Ölfilmstärke zu schließen. Außerdem ist die Behandlung störungsbedingter Meßfehler ein wichtiger Punkt der Arbeit.

Das hier vorgestellte Verfahren findet seine Anwendung in einem luftgestützten Überwachungssystem, das vorwiegend zur Abwehr von Gefahren für die Umwelt bestimmt ist, die von der Schifffahrt in der Nord- und Ostsee und den in der Nordsee stationierten Offshore-Anlagen ausgehen. Die Umweltgefährdung entsteht primär durch das unfallbedingte Freiwerden von Schadstoffen sowie durch das illegale Einleiten schadstoffbelasteter Abwässer.



Der hierzu benutzte Lösungsansatz des Sensorfusionsproblems basiert auf der Verwendung von Instantiierten Neuronalen Feldern, deren Dynamik letztlich dazu führen soll, daß man eine Repräsentation der Meßdaten erhält, die möglichst genau mit den realen Verhältnissen übereinstimmt.

Zur besseren Untersuchung der Neuronalen Felder werden im ersten Teil der Arbeit synthetische Testdaten erzeugt. Diese Daten werden später mit verschiedenen Arten von künstlichen "Meßfehlern" versehen.

Im Anschluß daran werden dann verschiedene Varianten eines Neuronalen Feldes vorgestellt. Die Feldvarianten sind dabei nach steigender Komplexität geordnet. Neben der allgemeinen Darstellung der Algorithmen wird auch die Bedeutung für die einzelnen Meßfehlerarten näher untersucht.

Der zweite Teil der Arbeit beschäftigt sich mit der experimentellen Untersuchung der Fehlertoleranz der einzelnen Feldvarianten. Die verschiedenen Dynamiken werden miteinander verglichen, und es wird näher auf die einflußnehmenden Parameter eingegangen.

Im letzten Teil der Arbeit werden schließlich Ölverteilungen auf der Basis realer Meßdaten untersucht. Neben der Vorstellung der Meßapparatur werden auch die damit in Zusammenhang stehenden Probleme aufgezeigt.

## **2 Grundlagen der Vermessung von Ölflecken**

### **2.1 Verwendung von Mikrowellen**

Im Gegensatz zum Seitensicht radar (Side Looking Airborne Radar, SLAR) gehören Mikrowellensensoren ebenso wie Kameras (IR- oder UV-Spektralbereiche) zu den Nahbereichssensoren. Mikrowellensensoren detektieren somit ebenfalls natürliche Strahlung.

Aufgrund der Empfindlichkeit im cm- und mm-Wellenlängenbereich sind Mikrowellensensoren allwettertauglich (Durchdringung von Wolken und Nebel, z. T. Regen) und eignen sich zur quantitativen Untersuchung starker Ölverschmutzungen.

Mikrowellensensoren ermöglichen durch die Ausnutzung von Interferenzeffekten an der Meeresoberfläche die Bestimmung von Schichtdicken von etwa 50  $\mu\text{m}$  bis zu einigen Millimetern, soweit es sich um Ölverschmutzungen auf der Wasseroberfläche handelt. Unterwasseröl ist nicht erfaßbar.

## 2.2 Planck'sche Wärmestrahlung

Jede Materie mit einer physikalischen Temperatur über  $0\text{ K}$  strahlt elektromagnetische Energie in Form von Wärme ab. Die meisten natürlichen Materialien verhalten sich dabei nur annähernd wie ein schwarzer Körper, dessen Emission durch das PLANCK'sche Strahlungsgesetz (vergl. [26]) beschrieben wird.

Bei einer Temperatur von  $300\text{ K}$  liegt das spektrale Intensitätsmaximum bei etwa  $\lambda = 10\ \mu\text{m}$  im tiefen Infrarot. Im Mikrowellenbereich ( $\text{mm}$  bis  $\text{dm}$ ) ist die Intensität um mehrere Größenordnungen kleiner.

Da alle realen Körper "grau" sind, setzt sich die abgestrahlte Energie aus der Eigenemission und der Umgebungsreflektion zusammen. Wenn sich diese beiden Komponenten stark genug unterscheiden, spricht man von "farbigem" Material.

Bei den hier benutzten Wellenlängen gilt das RAYLEIGH-JEANS-Gesetz (vergl. [26]) als Spezialfall des PLANCK'schen Strahlungsgesetzes

$$B_f = \frac{2k}{\lambda^2} T \quad \text{mit der Einheit} \quad [B_f] = \frac{\text{W}}{\text{m}^2 \text{ Hz sr}} . \quad (1)$$

Hierbei ist  $k$  eine Konstante,  $\lambda$  die betrachtete Wellenlänge und  $B_f$  die sog. Strahlungshelligkeit (frequenzabhängige Strahlungsleistung).

Es gilt somit das einfache Verhältnis  $B_f \sim T$ .

Die Temperatur  $T$  kann man aus der abgestrahlten Rauschleistung  $P_R$  bestimmen. Hierzu bedient man sich der Beziehung

$$P_R = k T \Delta f . \quad (2)$$

In Gleichung (2) ist  $\Delta f$  die Bandbreite der Messung.  $k$  ist wieder die Boltzmann-Konstante und  $T$  die beobachtete Temperatur, die sich aus der Eigenemission und der reflektierten Strahlung zusammensetzt.

Zusammenfassend läßt sich feststellen, daß die Messung von  $P_R$  ausreicht,

um  $B_f$  bis auf einen konstanten Vorfaktor zu bestimmen. Den auftretenden Vorfaktor kann man z. B. durch eine Referenzmessung ermitteln.

Gemessen wird die emittierte Wärmestrahlung mit sogenannten Radiometern. Im Prinzip handelt es sich dabei um Antennen, die die elektromagnetische Strahlung auffangen, bündeln und in rein elektrische Signale umsetzen.

### 2.3 Radiometer

Bei den hier verwendeten Frequenzen kommen sogenannte Hornantennen zum Einsatz. Durch ihre verschiedenen geometrischen Abmessungen arbeiten diese Antennen auf unterschiedlichen Eigenfrequenzen.

Die Stärke des empfangenen Signals hängt neben der eigentlichen Temperatur der gemessenen Wärmequelle (hier der Ölschicht auf der Wasseroberfläche) auch von der Meßfrequenz, der Polarisation, dem Beobachtungswinkel, dem Material und dessen Oberflächenbeschaffenheit ab.




Abbildung 1: Ansicht des Antennengehäuses von außen.

Abbildung (1) zeigt das Antennengehäuse von außen. Man erkennt drei Antennen in der Frontseite. Das Horn der linken Antenne mißt bei 18,7 GHz, das kleine in der Mitte bei 89,0 GHz und das Horn auf der rechten Seite bei 36,5 GHz. Details zur Anordnung der Antennen folgen an späterer Stelle.

Die 36 GHz–Antenne (hier die mittlere Meßfrequenz) hat dabei einen Öffnungswinkel von  $12^\circ$ , einen Öffnungsdurchmesser von 34,00 mm und eine Länge von 110,20 mm.

Das empfangene Mikrowellensignal wird zunächst vorverstärkt und gleichgerichtet. Anschließend wird der Offset korrigiert und nach nochmaliger Verstärkung steht das Meßsignal am Ausgang zur Verfügung (Schaltbild siehe Anhang B).

Nach einer Digitalisierung des Meßsignals kann man die Signalstärken auf eine Grauwertskala abbilden.

Die insgesamt empfangene Strahlung ist jedoch von sehr geringer Intensität<sup>1</sup>.

Die unterschiedlichen Grauwerte erlauben neben der Bestimmung der Ölschichtdicken prinzipiell auch eine Differenzierung unterschiedlicher Materialien, im vorliegenden Fall nicht nur Öl und Wasser, sondern sogar den Öltyp (Schweröl, Rohöl, Pflanzenöl, usw.). Da die Klassifizierung des Öltyps jedoch sehr stark durch die Witterung beeinflusst wird, nutzt man hierzu in der Regel eher einen Laserfluorosensor ([38]).

---

<sup>1</sup>Größenordnung etwa  $10^{-20} \dots 10^{-15}$  W

## 2.4 Signalqualität, prinzipielle Wahl der Frequenzen

Die gemessene Strahlung von Objekten in natürlicher Umgebung ist inkohärent, d. h. das Signal hat Rauschcharakter und muß daher vom Eigenrauschen innerhalb der Verstärkereinrichtung, speziell der Vorverstärkerstufe des Mikrowellenempfängers, unterscheidbar sein<sup>2</sup>. Ein Plot der gelieferten Meßwerte zeigt (siehe Abbildung (75), Seite 108), daß diese Bedingung in erster Näherung als erfüllt angesehen werden kann.

Die Wahl der Meßfrequenzen hängt zunächst einmal davon ab, was gemessen werden soll. Des weiteren spielen physikalische Gründe eine wesentliche Rolle bei der Festlegung. Der besondere Vorteil von Mikrowellen mit Wellenlängen von mehr als 2 cm ist z. B. deren Unempfindlichkeit gegenüber Wetterphänomenen. Schließlich müssen die Meßfrequenzen auch noch so gewählt werden, daß sie in geschützten Frequenzbereichen liegen, um Störungen durch zivile und militärische Funkdienste zu vermeiden.


Da alle benutzten Antennen über den gleichen Parabolspiegel umgelenkt werden, hängt die erreichbare Ortsauflösung auf der Meeresoberfläche direkt mit der Antennengeometrie und somit auch mit der Meßfrequenz zusammen<sup>3</sup>.

Abbildung (2) zeigen die Sensorbilder der Antennen bei den verschiedenen Meßfrequenzen. Die obere Bildreihe zeigt dabei die numerisch simulierte Abtastung eines Testdatensatzes, in der unteren Reihe sind realen Meßdatensätze dargestellt.

---

<sup>2</sup>Der technische Aufwand zur Reduktion des Verstärkerrauschens ist beträchtlich. Er schließt z. B. die Kühlung des Vorverstärkers auf 20 K mit Helium ein.

<sup>3</sup>Andere Meßaufbauten verwenden für jede Meßfrequenz einen eigenen Parabolspiegel, der dann auch zur Fokussierung benutzt wird. Der Vorteil der hier verwendeten Anordnung mit nur einem Spiegel liegt in der kompakteren Bauweise und dem geringeren Gewicht.




89 GHz

36 GHz

18 GHz

Abbildung 2: Antennenbilder (Simulation)



89 GHz

36 GHz

18 GHz

Abbildung 3: Antennenbilder (Reale Daten)

Wenn man die Bilder der drei Antennen betrachtet, stellt sich sofort die Frage, warum man die Messung nicht bei möglichst hohen Frequenzen durchführt (dann ist die Ortsauflösung am höchsten). Mindestens zwei Gründe sprechen jedoch dagegen:

1. Physikalische Gründe, hierbei speziell die Dämpfungserscheinungen durch Witterung und z. T. der Atmosphäre,
2. Probleme des Meßmodells mit Mehrdeutigkeiten.




Abbildung 4: Atmosphärische Absorptionsspektren für  $O_2$  (links) und  $H_2O$  (=Wasserdampf, rechts) bei 100 mbar und 1000 mbar, jeweils bei konstanter Temperatur. (Quelle: [24])

In Diagramm (4) ist das umgebende Störungs-niveau der Atmosphäre dargestellt. Die Luftmoleküle der Troposphäre<sup>4</sup> zeigen bei bestimmten Anregungsfrequenzen Resonanzerscheinungen. Die Resonanzen dämpfen das Meßsignal deutlich ab. Hierdurch verschlechtert sich das Verhältnis Nutz-signal zu Rauschen (Störsignal) drastisch.

<sup>4</sup>Troposphäre: Luftschichten bis 12 km Höhe über NN

Man sollte daher immer Frequenzen wählen, die nicht mit den Resonanzfrequenzen zusammenfallen.

Es wurde aber gerade im Zusammenhang mit Abbildung (2) festgestellt, daß möglichst hohe Frequenzen (= hohe Ortsauflösung) wünschenswert sind.

Dies ist im vorliegenden Fall aber nicht möglich, da zum einen die Dämpfung durch den atmosphärischen Wasserdampf in der Troposphäre stark mit der Meßfrequenz ansteigt (Abbildung (4), rechts).

Zum anderen beruht das derzeitige Meßmodell auf der Detektion von Interferenzerscheinungen an den Luft–Öl–Wasser–Grenzschichten. Wenn die Abtastwellenlängen in die Größenordnung der Ölschichtdicken kommen, dann können Mehrdeutigkeiten<sup>5</sup> in den Meßwerten die Folge sein.

Die folgende Abbildung (5) faßt die beiden Diagramme in einer einzigen Grafik zusammen. Sie zeigt die nicht–reduzierbaren Rauschtemperaturen einer idealen Antenne im Bereich von 100 MHz ... 100 GHz.

Die Minima der beiden dargestellten Dämpfungskurven markieren die sogenannten *atmosphärischen Fenster*. Diese Bereiche sind besonders vorteilhaft zur Messung geeignet.

Im Unterschied zu der vorangegangenen Abbildung (4) kann man zusätzlich erkennen, daß die Orientierung der Antenne einen wesentlichen Einfluß auf das Störungsniveau hat.

---

<sup>5</sup>vergl. Gleichung (3) auf Seite 11.




Abbildung 5: Atmosphärische Fenster im Frequenzspektrum. (Quelle: [24])

Die L-Antenne<sup>6</sup> arbeitet bei 18 GHz knapp unterhalb der Wasserdampf-Resonanz (22,235 GHz). Die M-Antenne mißt bei 36 GHz relativ genau zwischen den beiden Störungsmaxima und die 89 GHz H-Antenne mißt deutlich oberhalb des Sauerstoff-Peaks, der bei 60 GHz liegt.

<sup>6</sup>Antennenindizes: L=low (18,7 GHz), M=medium (36,5 GHz), H=high (89 GHz)

## 2.5 Modellkonforme Wahl der Meßfrequenzen

Der vorliegende Text baut auf einer Reihe von vorangegangenen Arbeiten auf, in deren Verlauf die Meßvorrichtung entwickelt und realisiert wurde ([27], [28], [29]).

In diesen Arbeiten wurde ein Interferenzmodell postuliert, welches einen Zusammenhang zwischen der empfangenen Signalstärke und der Öldicke auf der Wasseroberfläche beschreibt.

Interferenz infolge Reflektion an dünnen Grenzschichten wird durch ein Interferenzgesetz der Form

$$d \cdot \sin \varphi = n \cdot \frac{\lambda}{2} \quad (3)$$

beschrieben, wobei  $\varphi$  der Winkel zur Einfallsnormalen der Oberfläche,  $\lambda$  die betrachtete Wellenlänge und  $n$  eine ganzzahlige Konstante ist.

Die Lösungen der Gleichung (3) beschreiben konkret die Winkel  $\varphi_n$ , an denen Auslöschungen auftreten.

Dabei bezeichnet man die betrachteten Grenzschichten als *dünn*, solange in Gleichung (3) keine Mehrdeutigkeiten auftreten. In den vorliegenden Meßdaten treten jedoch Schichtdicken oberhalb von  $\frac{\lambda}{4}$  auf.

In den beobachteten Meßwerten führt dies zu Mehrdeutigkeiten, die sich durch die simultane Beobachtung mehrerer Frequenzen kompensieren lassen. Man wählt hierzu die Frequenzen so, daß die Mehrdeutigkeiten zumindest nicht auf allen Meßkanälen gleichzeitig auftreten.

Die mit dem Interferenzmodell in Zusammenhang stehenden Probleme werden in Abschnitt 6.2.3 näher dargestellt; sie sind jedoch insgesamt nicht Gegenstand dieser Arbeit.

Die prinzipielle Berücksichtigung von Mehrdeutigkeiten, die bei klassischen Verfahren mit erheblichem Aufwand verbunden ist, kann unter Benutzung der hier vorgestellten neuronalen Dynamiken sehr einfach und elegant gelöst werden.

### 3 Erzeugung synthetischer Testdaten

Für die nachfolgenden Untersuchungen werden Testdaten benötigt, die realistische Ölverteilungen auf Wasseroberflächen nachbilden.

Die Simulation solcher Verteilungen im Rechner erlaubt die isolierte Betrachtung einzelner Verarbeitungsaspekte in den nachfolgenden Kapiteln. Sie unterstützt außerdem die Entwicklung einer modularen Gesamtlösung, deren Komponenten separat getestet werden können.

Zunächst wird an dieser Stelle deshalb ein Programm vorgestellt, mit dem man diese simulierten Testdaten erzeugen kann.

Die synthetischen Testdaten werden interaktiv mit einem C-Programm erzeugt, das unter Unix/X11 läuft.

Der Benutzer des Programms kann mit der Maus Kreise "aufziehen", die dann den Rand einer Gaußglocke definieren. Der Begriff "Rand" soll in diesem Zusammenhang bedeuten, daß die Gaußfunktion hier bereits bis auf 10 % ihres Maximalwertes abgefallen ist. Der Radius dieser Gaußfunktion wird deshalb im folgenden mit  $R_{10}$  bezeichnet.

Zunächst wird das Maximum der Glocke so gewählt, daß das Volumen der Glocke auf 1 normiert ist. Dies soll später die Definition und Verifikation eines Fehlermaßes ermöglichen und vereinfachen.

Es muß nun die Varianz  $\sigma^2$  so berechnet werden, daß die Gaußfunktion im Abstand  $R_{10}$  vom Nullpunkt bereits auf 10 % des Maximums abgefallen ist. Das hierzu erforderliche  $\sigma$  ergibt sich




Abbildung 6: Der 10%-Rand einer Gaußverteilung

bei gegebenem  $R_{10}$  direkt aus der Definition der Gaußfunktion ([4]):

$$G(r) := \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2}\left(\frac{r}{\sigma}\right)^2} \quad (4)$$

$$G(r = R_{10}) \stackrel{!}{=} \frac{1}{10}G(r = 0) \quad (5)$$

$$\longrightarrow \sigma = \frac{R_{10}}{\sqrt{\ln 100}} \quad (6)$$

Mit diesem  $\sigma$  wird die 10 %-Bedingung erfüllt; unabhängig davon gilt  $\int_{-\infty}^{+\infty} G(r) \, dr = 1$ .

Der Übergang auf zweidimensionale, elliptische Verteilungen mit ansonsten gleichen Eigenschaften führt schließlich zu der Funktion ([4])

$$G(\vec{r}) := \frac{1}{2\pi\sigma_x\sigma_y} \cdot e^{-\frac{1}{2}\left[\left(\frac{x-\mu_x}{\sigma_x}\right)^2 + \left(\frac{y-\mu_y}{\sigma_y}\right)^2\right]} \quad \text{mit} \quad \vec{r} = \begin{pmatrix} x \\ y \end{pmatrix}. \quad (7)$$

Hierbei ergeben sich  $\sigma_x$  und  $\sigma_y$  aus den 10%-Grenzen,  $(\mu_x, \mu_y)$  bezeichnet den Mittelpunkt der Ellipse. Auch hier gilt die Normierung

$$\int \int_{-\infty}^{+\infty} G(\vec{r}) \, d\vec{r} = 1 \quad (8)$$

weiterhin. Die Normierung gestattet nach der Überlagerung (Summation) von mehreren Gaußglocken eine direkte Aussage über das Gesamtvolumen, da dieses dann genau<sup>7</sup> der Anzahl der Glockenkurven entsprechen muß.

---

<sup>7</sup>im Rahmen der Rechengenauigkeit: Da die 3D-Flächen hier durch diskrete Punkte repräsentiert werden, sind der Genauigkeit bei der Volumenbestimmung verhältnismäßig enge Grenzen gesetzt.

### 3.1 Programmtechnische Erzeugung der Testdaten

Das nebenstehende Bild zeigt die praktische Umsetzung des Datengenerators Synth. Die gewünschte Größe des Datenfeldes kann man als Argument auf der Befehlszeile angeben. Voreingestellt ist ein Format von  $136 \times 200$  Pixeln. Diese Größe entspricht

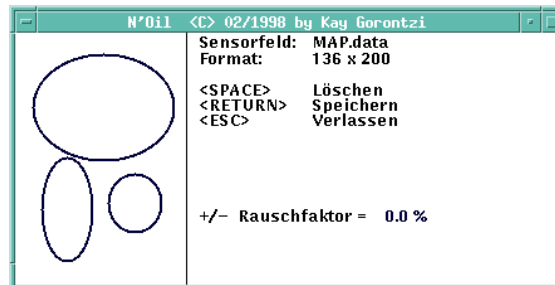


Abbildung 7: Hardcopy von Synth

zumindest horizontal den Datenfelddimensionen, die bei den realen Messungen verwendet wurden und die später in Abschnitt (6) benutzt werden sollen.

Bei Betätigung der `<RETURN>`-Taste werden die Daten in einem File namens `MAP.data` in folgendem Format abgelegt:

```
Breite = 136   Laenge = 200
1.3586710140559   1.4812413068809   1.7485158910190
1.4099742797607   1.5312941147211   1.8039246481042
...
0.0097200757877   0.0108601306884   0.0139921849447
0.0088624824941   0.0100830029616   0.0129771000476
...
1.4515800466920   1.5593890319671   1.8389681559597   1. Datenzeile
1.7108899617353   1.7674341192070   2.0201729893713
...
...
...
<-- Ende der
```

Tabelle 1: Datenformat der Ausgabe von Synth

Am Anfang des Files steht die Größe des simulierten Meßfeldes. In jeder folgenden Zeile stehen 3 simulierte Meßwerte, d. h. jede Spalte ist jeweils einem Sensor zugeordnet.

Wie man in Abbildung (7) erkennen kann, bietet das Programm außerdem die Möglichkeit, einen Rauschfaktor einzustellen. Diese Funktion wurde am

Anfang verwendet, um einen ersten qualitativen Eindruck von der Leistung der Algorithmen zu gewinnen.

Der einstellbare prozentuale Rauschfaktor bezieht sich dabei auf den Maximalwert der vorliegenden Daten. Mittels der systemeigenen `drand48()`-Funktion ([17]) wird ein gleichverteiltes, mittelwertfreies, weißes Rauschen<sup>8</sup> erzeugt.

Für die Überlagerung mit den Meßwerten hat man dann prinzipiell noch die Wahl, entweder ein mittelwertfreies oder ein Rauschen aus positiven Werten zu addieren. Ein Rauschsignal  $r(t)$  ohne negative Anteile ist nicht mittelwertfrei, da es einen Erwartungswert  $E\{r(t)\} > 0$  besitzt (vergl. [4]).

Für das mittelwertfreie Rauschen spricht, daß sich dadurch das Integral über alle Werte nicht verändert. Andererseits treten hierdurch negative "Meßwerte" auf, die in der Praxis nicht vorkommen. Hier wurde deshalb ein Rauschen ohne negative Anteile verwendet, da es besser den realen Verhältnissen in Abschnitt (6) entspricht.

### 3.2 Typen von Ölverteilungen

Mit dem beschriebenen Programm `Synth` lassen sich leicht Testdatensätze erzeugen, die den Grundtypen der auftretenden Ölfleck-Verteilungen entsprechen.

Die folgenden Abbildungen sollen einen Überblick über die möglicherweise auftretenden Verteilungssituationen geben.

Die absoluten Dickenwerte spielen in den folgenden Darstellungen zunächst noch keine Rolle. Sie wurden daher so skaliert, daß sie den darstellbaren Wertebereich voll abdecken.

---

<sup>8</sup>vergl. Literatur aus der Elektrotechnik [5], [11], [4]

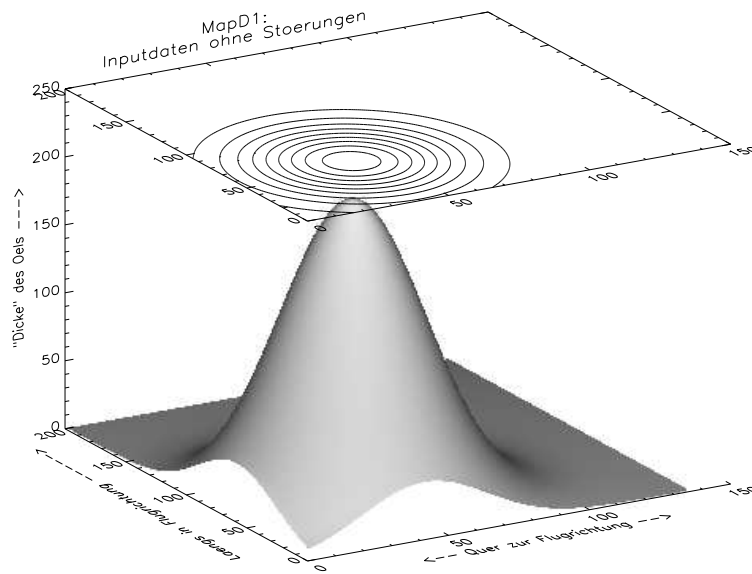


Abbildung 8: ( $D_1$ ) Gaußförmig simulierter Ölfleck. An diesem sehr einfachen Datensatz kann man die prinzipiellen Auswirkungen der einzelnen Varianten des neuronalen Feldes besonders einfach untersuchen.

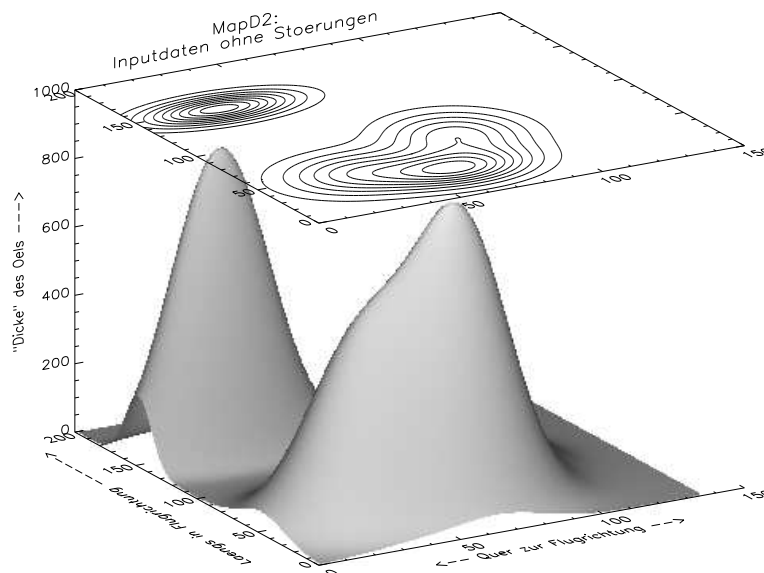


Abbildung 9: ( $D_2$ ) Eine Verteilung mit zwei Erhebungen. Obwohl die Maxima relativ dicht beieinander liegen, sollen sie von dem neuronalen Feld sauber getrennt werden. Die beiden Ölbereiche fließen nicht ineinander.

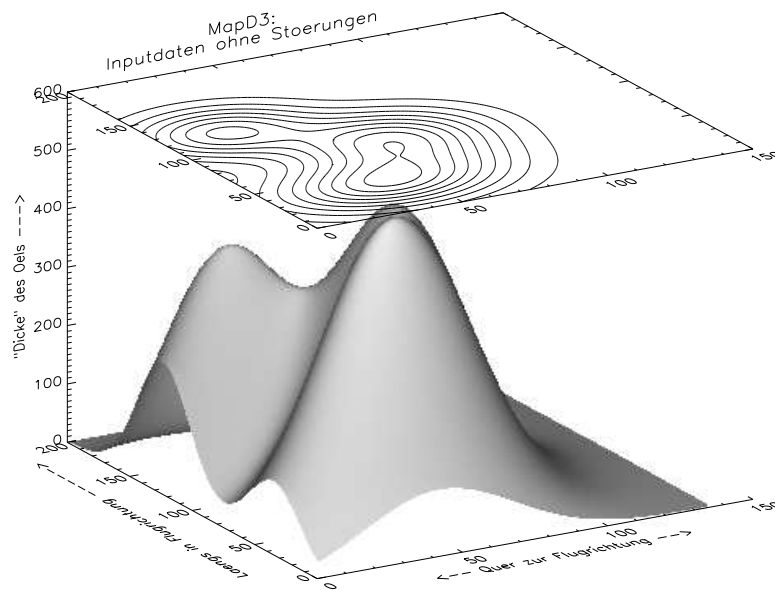


Abbildung 10: ( $D_3$ ) Simulierter "Ölfleck", der relativ flach ist und der mit seiner Verteilung einem realen Ölfleck nahe kommt. Die verschiedenen auftretenden Maxima gehen ineinander über.




Abbildung 11: ( $D_4$ ) Zwei simulierte Ölbereiche mit räumlicher Trennung. Die Flecken sind nicht einfach-zusammenhängend und haben verbundene Maxima.

### 3.3 Simulation von Störungen

Die generierten Daten entsprechen zunächst jeweils einer Öldickenverteilung, wie sie in der Realität vorhanden sein könnte. Die Dickenverteilung der Realität kann jedoch nur indirekt durch die Sensormessung ermittelt werden. Daher müssen auch die simulierten Dickenwerte so vorverarbeitet werden, daß sie sich möglichst wenig von den tatsächlichen Meßwerten unterscheiden. Dies gilt vor allem im Hinblick auf die während einer Messung auftretenden Störungen.




Abbildung 12: Simulation einer einfachen Meßkette

Abbildung (12) zeigt den Aufbau einer einfachen Meßkette. Sie besteht in diesem Fall aus der simulierten Dickenverteilung am Eingang, einer simulierten *Antennenabtastung* (siehe nächster Abschnitt) und einer Störungsstufe, die die Daten auf verschiedene Weise mit Störungen überlagert.

Die wichtigsten Parameter einer Antennenabtastung ergeben sich aus der Geometrie der Antenne. Da die physikalischen Abmessungen der Antennen im vorliegenden Fall bekannt sind, können die Abtastparameter gut bestimmt werden. Die so erhaltenen Daten stimmen daher weitgehend mit den Daten bei einer realen Messung überein.

Erheblich problematischer ist die Parameterwahl für die nachfolgende Meßelektronik. Die genauen Störungsparameter dieses Teils der verwendeten Apparatur sind bisher noch gar nicht identifiziert worden.

In dieser Arbeit soll daher ein *verallgemeinertes Störungsmodell* angewendet werden. Mit den Parametern dieses Modells kann man die prinzipiell vorkommenden Störungen ggf. gezielt nachbilden.

Die einzelnen Komponenten dieses Modells (Abtastung, Offsets, Rauschen, u.s.w.) werden im folgenden vorgestellt und am Ende dieses Kapitels auf Seite 30 in Abbildung (18) zusammengefaßt.

Das allgemeinere Modell hat darüber hinaus den Vorteil, daß es keine Annahmen über Ursache und Ort einer auftretenden Störung macht. Es ist daher nicht nötig, einzelne Elemente der realen Meßapparatur individuell als Störungsquellen zu identifizieren und zu beschreiben.

### 3.3.1 Abtastung mit virtuellen Antennen

Zunächst werden die Daten mit drei virtuellen Antennen abgetastet. Die Abtastung der Wasseroberfläche mit einer realen Antenne bedeutet, daß die Temperaturverteilung jeweils über eine runde Zone gemittelt wird. Diese Zone ergibt sich als Schnitt der sog. Hauptkeule der Antennenempfangs-Charakteristik mit der Wasseroberfläche. Man nennt diese Schnittfläche bezeichnenderweise den *Footprint* der Antenne.

Da bei synthetischen Daten natürlich keine Antennen zur Verfügung stehen, werden die Daten auch nur im mathematischen Sinne abgetastet. Die Abtastung ist im Prinzip eine gewichtete Mittelung der Meßpunkte innerhalb des Footprints, wobei als Gewichtsfunktion wieder eine Gaußglocke Verwendung findet. Der Rand des Footprints ist die -3 dB-Grenze der Gaußglocke, das ist der Ort, an dem deren Betrag auf  $\frac{1}{\sqrt{2}}$  des Maximalwertes abgefallen ist.

Wenn die Werte innerhalb des Footprints konstant sind, sollte die Gewichtsfunktion genau diesen konstanten Wert als Abtastwert liefern.

Eine entsprechende Gewichtung wird im folgenden bestimmt.

Der gewichtete<sup>9</sup> Mittelwert  $\tilde{m}$  über den Footprint einer Antenne, dessen diskrete Abtastpunkte  $\vec{r}_i$  den Definitionsbereich  $\mathbb{D}$  darstellen, sei

$$\tilde{m} := \frac{\sum w(\vec{r}_i) m(\vec{r}_i)}{\sum w(\vec{r}_i)} \quad \forall \vec{r}_i \in \mathbb{D} . \quad (9)$$

Die Gewichtsfunktion  $w(\vec{r}_i)$  soll nun die Form einer Gaußglocke haben. Zunächst gilt allgemein (vergl. Gleichung (7))

$$G(\vec{r}) := \frac{1}{2\pi\sigma_x\sigma_y} \cdot e^{-\frac{1}{2}\left[\left(\frac{x-\mu_x}{\sigma_x}\right)^2 + \left(\frac{y-\mu_y}{\sigma_y}\right)^2\right]} \quad \text{mit} \quad \vec{r} = \begin{pmatrix} x \\ y \end{pmatrix} . \quad (10)$$

Da die Footprints kreisrund um den Mittelpunkt  $\begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix}$  gewählt wurden, ist  $\sigma_x \equiv \sigma_y$ . Man kann deshalb vereinfachend ein gemeinsames

$$\sigma_w := \sigma_x = \sigma_y \quad (11)$$

definieren. Analog zu Abschnitt (3) kann man für dieses  $\sigma_w$

$$\sigma_w = \frac{R_{\text{Antenne}}}{\sqrt{\ln 2}} \quad (12)$$

bestimmen. Im Unterschied zu Abschnitt (3) liegt der Rand der Gaußfunktion hier nicht bei 10 %, sondern bei einem Abfall von -3 dB, d. h. auf  $\frac{1}{\sqrt{2}}$ .

Die Gewichtsfunktion  $w(\vec{r}_i)$  lautet somit insgesamt

$$w(\vec{r}_i) = G'(\vec{r}_i) = e^{-\frac{1}{2\sigma_w^2}[(x_i - \mu_x)^2 + (y_i - \mu_y)^2]} \quad \text{mit} \quad \vec{r}_i = \begin{pmatrix} x_i \\ y_i \end{pmatrix} . \quad (13)$$

Gegenüber Gleichung (10) ist außerdem der konstante Vorfaktor  $\frac{1}{2\pi\sigma_w^2}$  in  $w(\vec{r}_i)$  entfallen. Dieser fällt bei der Bildung des gewichteten Mittelwertes über Gleichung (9) ohnehin heraus, da man ihn dort kürzen kann.

---

<sup>9</sup>Gewichtete Mittelwerte werden in Abschnitt 4.1.4 genauer definiert.

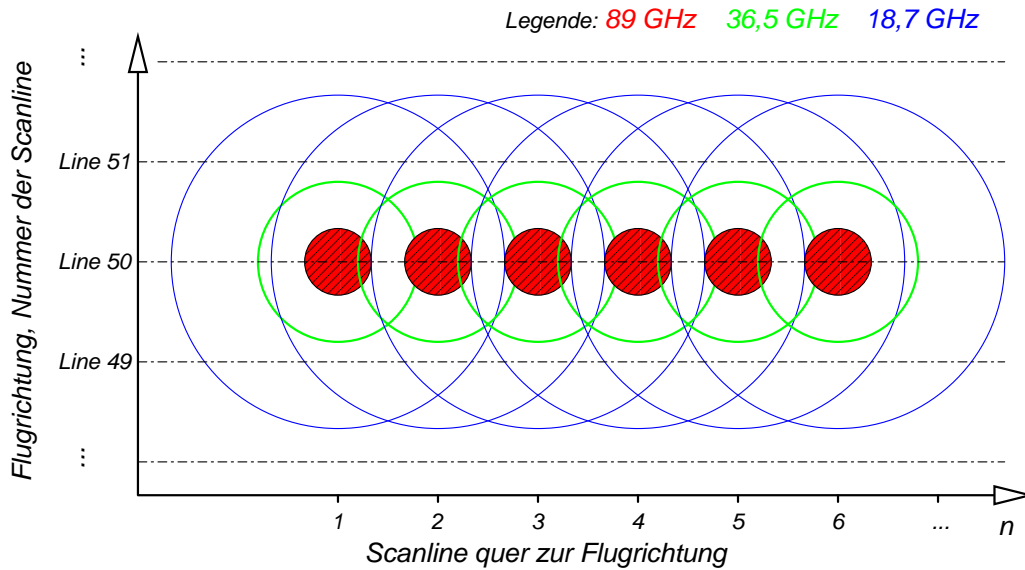


Abbildung 13: Radien und Position der Antennenfootprints in einer Scanline

Um problemangepaßt zu verfahren, wird die Größe der Gaußlocken der Größe der drei realen Antennen-Footprints nachempfunden: Die Antenne zum Empfang der höchsten Frequenz (Index  $H$ ) mißt nicht-überlappend, d. h. sie tastet z. B. immer nur einen einzelnen Meßpunkt ab (rot markierter Bereich in Abbildung (13)). Die übrigen Antennen mitteln jeweils über mehrere benachbarte Meßpunkte (grün und blau markierte Zonen in Abbildung (13)). In der Simulation wird der Radius der 89 GHz-Antenne auf  $r_H := 1$  definiert. Die Footprint-Radien der Antennen verhalten sich reziprok zu ihren Eigenfrequenzen:

Antenne	Frequenz	Radius $R$	Parameter $\sigma_w$	$\sigma$ -Wert
H = hoch	89 GHz	1,0	$\sigma_H$	1,2010
M = mittel	36 GHz	2,5	$\sigma_M$	3,0028
L = niedrig	18 GHz	5,0	$\sigma_L$	6,0056

Tabelle 2: Werte zu Gleichung (12)

Die Footprint-Radien der übrigen Antennen wurden also so gewählt, daß deren Verhältnisse den realen Antennenverhältnissen entsprechen.

Für jeden Meßpunkt wird damit Gleichung (9) für alle Punkte des jeweiligen Footprints ausgewertet.

Mathematisch kann man dies auch als eine *Faltung im Ort* interpretieren: wenn man eine Matrix  $W$  mit einer in der Mitte zentrierten Funktion  $w(\vec{r}_i)$  erzeugt, kann man diese Matrix als Filterkern einer Faltung benutzen. Die Faltung des Datenfeldes mit dieser Matrix liefert so auf elegante Weise die gewünschte Abtastung, also etwa für die H-Antenne

$$M_H = W_H * M . \quad (14)$$

Hierbei ist  $M$  die Matrix der synthetischen "Meßwerte",  $W_H$  die Matrix aus den  $w(\vec{r}_i)$  mit  $\sigma_H$ , und  $M_H$  die Matrix mit den so abgetasteten "Meßwerten".

Der Faltungsoperator '\*' ist im 1-dimensionalen Fall durch die Gleichung

$$f_1(x) * f_2(x) := \int_0^x f_1(q) f_2(x - q) \, dq \quad (15)$$

definiert. Da hier mit flächig verteilten Daten gearbeitet wird, ist eine Erweiterung auf zwei Dimensionen erforderlich:

$$f(x, y) * g(x, y) := \int_0^x \int_0^y f(\tilde{x}, \tilde{y}) \cdot g(x - \tilde{x}, y - \tilde{y}) \, d\tilde{x} \, d\tilde{y} . \quad (16)$$

Der Übergang auf diskrete Werte führt schließlich auf eine gewichtete Mittelwertbildung über alle Punkte.

Die folgenden Abbildungen sollen einen Eindruck davon vermitteln, wie sich diese Faltung auf die Daten auswirkt, die die Antennen liefern.





Abbildung 14: Simulierte Ölverteilung (ohne Störungen, vor der Abtastung)

Abbildung (14) zeigt eine simulierte Ölverteilung in der Aufsicht. Die drei folgenden Bilder zeigen deren Faltung mit den Antennencharakteristiken. Die gewählten Verhältnisse der Footprint-Radien entsprechen dabei Tabelle (2).





Im Bild der simulierten 89 GHz Antenne erscheint die Verteilung noch sehr deutlich. Da diese Antenne an jeder Meßposition nur wenige simulierten Meßwerte "sieht", war auch keine starke Veränderung in der Verteilung zu erwarten.

Der Einfluß des Rauschens ist in der Randzone deutlich zu erkennen. (Die vereinzelt roten Meßpunkte entstehen durch sog. *Spikes*, siehe Abschnitt 3.3.4).

Die 36 GHz Antenne mittelt bei der Messung über einen 2,5 mal größeren Radius, d. h. über eine 6,25 mal so große Fläche. Hierdurch erscheint die Verteilung "verwischt".

Die Antenne vermittelt eine ideale, nichtkausale Tiefpaßfilterung ([20]). Dadurch erscheint ein Meßsignal  $> 0$  in Bereichen, in denen sich eigentlich gar kein Öl befindet.



Der Effekt verstärkt sich, je niedriger die Antennenfrequenz ist.

Die 18 GHz Antenne mittelt bei der Messung über einen nochmals verdoppelten Radius. Hierdurch erhöht sich die abgetastete Fläche gegenüber der 89 GHz Antenne sogar um den Faktor 25.

### 3.3.2 Offsetfehler

Der Meßkanal jeder Antenne kann um einen festen Betrag vom *wahren Wert*<sup>10</sup> abweichen. Dies äußert sich in einem systematischen Fehler. Man bezeichnet diese Abweichung als Offset-Fehler ([11]) und meint damit die gleichmäßige Verschiebung aller Meßwerte in eine Richtung.




Abbildung 15: Offsetverschiebung

Realisiert wird die Offset-Berücksichtigung in der Simulation durch die Addition eines festen, kanalcharakteristischen Wertes zum jeweiligen Meßwert.

Offsetfehler sind im allgemeinen Kalibrierungsfehler. Man kann sie daher in der Vorverarbeitung der Daten mittels einer Nullmessung<sup>11</sup> detektieren und eliminieren.

Im folgenden werden die Offsets daher zunächst als Null angenommen.

An dieser Stelle soll nochmals wiederholt werden, daß die vorgestellten Fehlerquellen jeweils nur exemplarisch für einen bestimmten Fehlertyp verstanden werden sollten.

Offsetfehler entstehen beispielsweise nicht nur an den Antennen, sondern z. B. ebenfalls in den Verstärkerstufen, bei der Digitalisierung der Meßwerte u.s.w. .

---

<sup>10</sup>Der Temperaturwert, den eine ideale, exakt kalibrierte Antenne messen würde.

<sup>11</sup>Ohne anliegendes Sensorsignal.

### 3.3.3 Kanalrauschen

Jedem Meßkanal ist ein Rauschsignal  $r(t)$  überlagert, das z. B. in der Meßapparatur selbst seinen Ursprung haben kann. Dieses Kanalrauschen ist zwischen den einzelnen Sensoren nicht korreliert und möglicherweise betragslich sogar verschieden groß.

Das Rauschen ist typischerweise weiß<sup>12</sup>, stationär und mittelwertfrei. Es wird hier numerisch wieder durch gleichverteilte Zufallszahlen in einem Intervall  $[0, \dots, +\alpha_r]$  erzeugt<sup>13</sup> und dem Meßsignal additiv überlagert.

Da der Erwartungswert (vergl. [4]) der gewählten Rauschfunktion

$$E\{r(t)\} > 0 \quad (17)$$

ist, wirkt sich das auch ungünstig auf die Metrik  $\epsilon_V$  aus, die weiter unten in Abschnitt 4.3 definiert wird.

### 3.3.4 Spikes

Spikes<sup>14</sup> sind in der Elektrotechnik sehr kurze, transiente Störungen, die z. B. durch elektrische Entladungen an der Meßapparatur entstehen können (vergl. [11]). Sie treten dann typischerweise korreliert auf allen Kanälen gleichzeitig, evtl. allerdings mit unterschiedlichen Amplituden, auf.


---

<sup>12</sup>Weißes Rauschen heißt:  $\frac{dP}{df}$  ist frequenzunabhängig; siehe [5], [11].

<sup>13</sup>Damit ist es hier natürlich nicht mehr mittelwertfrei.

<sup>14</sup>Der englische Begriff *Spike* ist hier präziser als der deutsche Begriff *Signalspitze*, da es sich bei letzterem auch um deutlich längere Erscheinungen (*Peaks*) handeln kann. In der Literatur wird oft nicht sauber zwischen den Begriffen *Peaks* und *Spikes* getrennt; manchmal werden die Begriffe dort sogar synonym benutzt.

Spikes zeichnen sich durch extrem kurze Anstiegszeiten (hier wenige  $10^{-15}$  Sekunden) aus, d. h. durch ein sehr großes  $\frac{\partial m}{\partial t}$ . Sie klingen im allgemeinen etwas langsamer ab; die Abfallzeit ist also meist etwas länger als die Anstiegszeit.

Abbildung 16: Meßwert  $m(t)$  mit Spikes

In der graphischen Darstellung äußern sich Spikes als isolierte Punkte der jeweiligen Meßkurve, die sich in der Regel deutlich von ihrer Umgebung abheben.

Spikes stellen ein besonderes Problem bei der Meßdatenverarbeitung mit klassischen Verfahren dar, da diese Verfahren nicht erkennen, daß es sich um einen fehlerhaften Meßwert handelt.

### 3.3.5 Ausreißer

In gewisser Hinsicht kann man auch Spikes als Ausreißer bezeichnen. Hier jedoch sind nur solche Ausreißer gemeint, die bedingt durch den Meßvorgang nur auf einem einzelnen Kanal auftreten.

Neben den Ausreißern, die bei der Aufnahme eines einzelnen Meßwertes auftreten, können Ausreißer auch durch periodische Störungen in der Meßanordnung auftreten.




Abbildung 17: Ausreißer

Bei stetig verlaufender Meßkurve äußern sich Ausreißer durch das Auftreten von isolierten Meßpunkten, die nicht auf der Hauptkurve liegen.

In der Störungssimulation werden auch hier wieder alle Abweichungen positiv angesetzt.

### 3.3.6 Sättigung

Manchmal können bei realen Sensoren Sättigungseffekte bei sehr großen und sehr kleinen Meßwerten auftreten. Im Sättigungsbereich verhalten sich die meisten Sensoren nichtlinear und liefern deshalb Werte, die mit einer konventionellen Mittelung nicht sinnvoll weiterverarbeitet werden können.

Es wird sich zeigen, daß der Sättigungsfall für die hier benutzen Verfahren relativ unproblematisch ist. Ein konstanter Wert (z. B. ein oberer Grenzwert infolge Übersteuerung eines Meßverstärkers) kann jedoch das Ergebnis ungünstig beeinflussen.

### 3.3.7 Totalausfälle

Gelegentlich kann ein Sensor komplett ausfallen. In diesem Fall liefert er entweder konstante Werte oder aber sein Ausgang geht dauerhaft in die Sättigung beim Maximal- oder Minimalwert.

Auch hier wird sich zeigen, daß die neuronale Dynamik letztere Fälle relativ einfach kompensieren kann. Die Detektion und Berücksichtigung eines konstanten Wertes ist jedoch komplizierter. Wenn Fehler von diesem Typ ebenfalls berücksichtigt werden müssen, dann sollte man dem Neuronalen Feld eine einfache Vorverarbeitungsstufe vorschalten; die fraglichen Meßwerte sind relativ leicht detektierbar und können ausgesondert werden, damit sie die Dynamik des Neuronalen Feldes nicht negativ beeinflussen.

### 3.4 Zusammenfassung der Störungsparameter

Die verschiedenen Verarbeitungsschritte werden in der folgenden Abbildung (18) zusammenfassend dargestellt. Zuvor sollen allerdings noch die verwendeten Parameter in Tabelle 3 aufgelistet werden:

Parameter	Wertebereich	typ. Wert	Bedeutung
$R_H$	1 ... 10	1,0	Footprint, höchstauflösende Antenne
$R_M$	2 ... 20	2,5	Footprint, mittlere Antenne
$R_L$	3 ... 90	5,0	Footprint, niedrigste Frequenz
$A_H$	-100 ... + 100	0,0	Offset der H-Antenne
$A_M$	-100 ... + 100	0,0	Offset der M-Antenne
$A_L$	-100 ... + 100	0,0	Offset der L-Antenne
$\alpha_H$	0% ... 30%	10,0%	Rauschanteil auf dem H-Kanal
$\alpha_M$	0% ... 30%	10,0%	Rauschanteil auf dem M-Kanal
$\alpha_L$	0% ... 30%	10,0%	Rauschanteil auf dem L-Kanal
$N_{Sp}$	0 ... + $\infty$	50	Abstand zwischen den Spikes
$D_{Sp}$	0 ... + $\infty$	1000	Spike-Amplitude
$N_A$	0 ... + $\infty$	1000	Abstand zwischen Ausreißern
$D_A$	0 ... + $\infty$	100	Ausreißer-Amplitude
$U_{sat}$	90 ... + 99%	95,0%	Sättigungs-Amplitude

Tabelle 3: Parameter der Störungskette

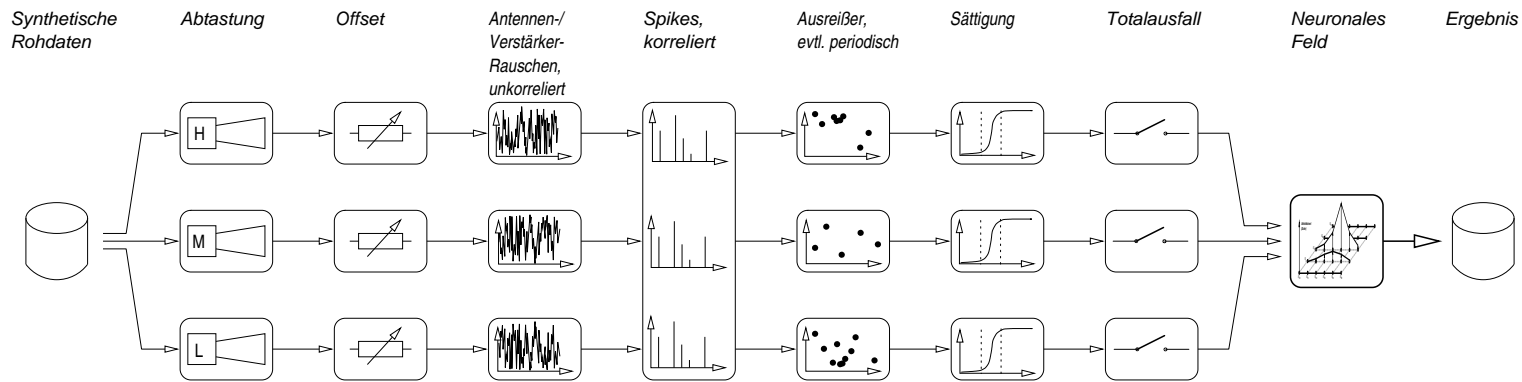


Abbildung 18: Störungskette von den synthetischen Rohdaten bis zur Ausgabe des Neuronalen Feldes

Auf jedem einzelnen der drei Meßkanäle werden folgende Operationen durchgeführt:

- Die simulierten Daten werden zunächst mit der jeweiligen Antennencharakteristik abgetastet.
- Zu jedem Datenwert wird ein konstanter, kanalabhängiger Offset addiert.
- Auf alle Datenpunkte wird ein Rauschen addiert.
- Auf allen drei Kanälen werden synchrone Spikes addiert.
- Die Meßwerte jedes Kanals werden mit asynchronen Ausreißern 'verunreinigt'.
- Relativ große und relativ kleine Meßwerte werden gekappt.
- Bei Totalausfall werden ganze Meßwertgruppen zu Null gesetzt.

Anschließend werden die Daten in das Neuronale Feld eingespeist.

## 4 Sensorfusion mit Neuronalen Feldern

### 4.1 Grundlagen

#### 4.1.1 Sensorfusion

Wenn *eine* physikalische Größe mit *mehreren* Meßgeräten *gleichzeitig* erfaßt wird, erhält man zu jedem Wert der physikalischen Größe mehrere Meßwerte. Man denke etwa an eine Temperaturmessung in einer Flüssigkeit mit mehreren Thermometern.

Im Idealfall sollten alle Instrumente die gleiche Temperatur anzeigen, jedoch ist dies in der Praxis selten der Fall. Im allgemeinen werden die einzelnen Meßgeräte zwar ähnliche, jedoch unterschiedliche Werte anzeigen. Aus diesen Werten muß nun eine Größe bestimmt werden, die dem realen Temperaturwert möglichst nahe kommen soll.

Das hierbei entstehende Problem wird als *Sensorfusionsproblem* bezeichnet.

Eine einfache Lösung wäre im beschriebenen Fall die Bildung eines arithmetischen Mittelwertes. Sofern die Meßwerte gleichmäßig um den wirklichen Wert streuen, liefert diese Vorgehensweise akzeptable Resultate und wird daher in der Praxis auch oft eingesetzt. Hat jedoch einer der Meßfühler einen Kalibrierungsfehler (systematischer Fehler), so daß er etwa ständig 2 Grad zuviel anzeigt, dann sind hinterher alle gebildeten Mittelwerte der Messung mit einem Fehler behaftet.

Erhält man bei mehreren Meßfühlern von einem stets Werte, die von allen übrigen deutlich abweichen, so erscheint es naheliegend, diesem Fühler weniger zu "vertrauen" als den anderen. Statt also einfach einen arithmetischen Mittelwert zu bilden, werden den Meßfühlern Gewichtungen zugeordnet, die deren Einfluß auf das Gesamtergebnis modifizieren können.

Die "Glaubwürdigkeit" der Meßgeräte muß hier jedoch durch Beobachtung und manuelle Bewertung festgelegt werden.

Wünschenswert wäre hingegen eine automatische Festlegung der Gewich-

tungen durch ein Verfahren, das auch im laufenden Betrieb auftretende Veränderungen erkennt und bewertet.

Genau dies leisten neuronale Dynamiken in besonders bequemer und eleganter Weise.

Neben der Reduktion von Kalibrierungsfehlern eignen sich dynamische Systeme darüber hinaus zur Elimination von verschiedenen anderen Störungen (Ausreißer, Spikes, Rauschen, etc.).

Es erscheint daher sinnvoll und erfolgversprechend, das Sensorfusionsproblem mit Neuronalen Feldern zu erproben.

#### 4.1.2 Neuronale Felder

Dynamische Neuronale Felder sind ortskontinuierliche dynamische neuronale Netzwerke mit definierter topologischer Struktur (vergl. [1], [2], [3]).

Sie erlauben die Bildung von Modellen, mit denen man u. a. die Aktivitätsdynamik in den kortikalen Neuronen biologischer Systeme beschreiben kann (vergl. [19]).

Ein Anwendungsfeld hierzu ist z. B. die visuelle Perzeption. Neben den Untersuchungen zur prinzipiellen Funktionsweise existieren auch bereits technische Systeme, etwa Robotersteuerungen ([33]), die Neuronale Felder zur Orientierung nutzen.

Die in dieser Arbeit auftretenden Meßdaten sind zweidimensional strukturiert, da sie die Öldicken auf einer Wasserfläche wiedergeben. Es ist somit naheliegend, die neuronale Datenrepräsentation mit einer vergleichbaren Struktur darzustellen.

Das hier verwendete Feld besteht deshalb aus einer zweidimensionalen, gitterartigen Anordnung von Neuronen (Abbildung (19)).




Abbildung 19: Zweidimensionale Feldstruktur

Die Neuronen auf den Punkten des orthogonalen Gitters sind alle gleich strukturiert, d. h. es wird beispielsweise nicht zwischen den inneren Neuronen und den Randneuronen unterschieden. In diesem Sinne ist das verwendete Neuronale Feld homogen.

Jedem Gitterpunkt wird genau ein Meßpunkt zugeordnet, so daß sich das Neuronale Feld verzerrungsfrei auf einen zu untersuchenden Ölfleck projizieren läßt.

Die Erregung<sup>15</sup> der einzelnen Neuronen (vergl. [18]) kann dann direkt als Repräsentation der Ölschichtdicke am jeweiligen Gitterpunkt interpretiert werden, was in Abschnitt (4.2) noch präzisiert wird.

Jedes einzelne Neuron empfängt als Input die Sensordaten zu einem einzelnen Meßpunkt. Die Sensordaten kommen im hier betrachteten Fall von mehreren Radiometerantennen, die multispektral in verschiedenen Frequenzbereichen die Mikrowellen-Emissionen/-Reflexionen der Meeresoberfläche messen.

Darüber hinaus interagieren die hier verwendeten Neuronen mit ihren lateralen Nachbarn. Die daraus resultierende Wechselwirkung ist eine besonders vorteilhafte Eigenschaft Neuronaler Felder und wird in Abschnitt (4.6) näher untersucht.

---

<sup>15</sup>Die *Erregung* ist eine Zustandsgröße bei biologischen Nervenzellen (Neuronen). Je stärker eine solche Zelle exzitatorisch gereizt wird, desto höher wird die Pulsfrequenz (=Erregung) am Ausgang (dem Axon) der Zelle. Details zum Aufbau von biologischen Nervensystemen finden sich z. B. in [18] und der einschlägigen Literatur zur Neurologie.

Durch die laterale Wechselwirkung unterscheidet sich die hier vorgestellte Art der Sensorfusion von klassischen Verfahren, die lediglich lokal arbeiten.

### 4.1.3 Konvergenzbegriff

Die Aktivitätsverteilung im Neuronalen Feld setzt sich für jeden Feldort  $N_{ij}$  aus der Einkopplung der Sensordaten und dem Einfluß der Nachbarneuronen zusammen, mit denen das Neuron  $N_{ij}$  wechselwirkt. Die laterale Kopplung der wechselwirkenden Neuronen führt im allgemeinen zu einem instabilen, z. B. fluktuierenden, *Erregungszustand* des gesamten Feldes.

Durch passende Wahl der Anzahl und Gewichtung der wechselwirkenden Neuronen kann man aber erreichen, daß sich das Feld selbst stabilisiert (sog. *Selbstorganisation*) und sich die Erregungsverteilung über der Zeit nicht mehr verändert. Dieses Verhalten des Feldes wird im folgenden als *konvergent* bezeichnet. Der daraus resultierende stabile Zustand des Feldes ist ein *Fixpunkt* im Zustandsraum des Feldes.

Nur solche stabilen Zustände (die, wie später gezeigt wird, vom Anfangszustand der Felderregung abhängen) stellen im vorliegenden Fall eine sinnvolle Schätzung der zu messenden physikalischen Größe dar und werden daher als "Output" des Sensorfusionsprozesses bezeichnet.

### 4.1.4 Gewichtete Mittelwerte

In der vorliegenden Arbeit werden Gewichtsfunktionen verwendet, die sich geringfügig von denen unterscheiden, die sonst im Bereich der Neuronalen Felder ([2], [3], [12], [19]) bei den entfernungsabhängigen Nachbarschaftswechselwirkungen verwendet werden.

Unter dem Begriff *Mittelwert* versteht man gewöhnlich das arithmetische Mittel ([10])

$$\bar{m} = \frac{1}{N} \sum_{i=1}^N m_i . \quad (18)$$

In der vorliegenden Arbeit wird jedoch häufig mit *gewichteten Mittelwerten* operiert. Einen *gewichteten Mittelwert* definiert man im allgemeinen als

$$\tilde{m}_{INT} := \frac{\int_a^b w(x) m(x) dx}{\int_a^b w(x) dx} \quad \text{mit } \mathbb{D} = [a; b] . \quad (19)$$

In dieser Gleichung steht  $m(x)$  für einen Meßwert;  $\mathbb{D}$  ist das Intervall, auf dem die Mittelung stattfindet. Die Anforderungen an die gewichtende Funktion  $w(x)$  sollen in diesem Abschnitt kurz zusammengefaßt werden.

Da in der Regel keine zeitkontinuierlichen Meßwerte vorliegen, reicht es, für diskrete  $m(x_i)$  auch nur eine diskrete Gewichtsfunktion  $w(x_i)$  zu definieren:

$$\tilde{m} := \frac{\sum w(x_i) m(x_i)}{\sum w(x_i)} \quad \forall x_i \in \mathbb{D} . \quad (20)$$

Die Definitionsgleichung (20) soll im folgenden vorausgesetzt werden, wenn ein gewichteter Mittelwert gebildet werden soll.

Wie nun gezeigt werden soll, unterliegt die diskrete Gewichtsfunktion  $w(x_i)$  keinen wesentlichen Beschränkungen. Dennoch kann es sinnvoll sein, sie normiert zu wählen.




Abbildung 20: Gewichtungen

Das nebenstehende Bild zeigt die Graphen zweier Funktionen  $f_1$  und  $f_2$ . Darunter sind drei Gewichtsfunktionen  $w_1, w_2, w_3$  dargestellt, mit denen jeweils die Mittelwerte von  $f_1$  und  $f_2$  gewichtet werden sollen.

Zur Bildung der Mittelwerte wird jeweils Gleichung (20) herangezogen. Die Ergebnisse der jeweiligen Mittelwertbildung sind in der nachfolgenden Tabelle (4) zusammengefaßt. Zum besseren Vergleich ist außerdem das

arithmetische Mittel aufgenommen worden. In der Tabelle erkennt man direkt, daß eine beliebige Wahl der Gewichtsfunktion  $w(x)$  für konstante

Art der Mittelwertbildung	Funktion $f_1$	Funktion $f_2$
arithmetisches Mittel	3,00	4,97
gewichtet mit $w_1$	3,00	4,89
gewichtet mit $w_2$	3,00	5,27
gewichtet mit $w_3$	3,00	5,64

Tabelle 4: Auswirkung verschiedener Gewichtungen

Funktionen wie  $f_1$  genau deren Funktionswert liefert. Dies ist mit der intuitiven Erwartung an eine 'normale' Mittelwertbildung konform und die erste wichtige Eigenschaft (I) von Gleichung (20).

Bei der Rampenfunktion  $f_2$  erkennt man jedoch deutliche Unterschiede, je nach Wahl von  $w(x)$ . Während  $w_1$  einen deutlichen Schwerpunkt auf den Abschnitt  $x_i > 4$  der Funktion legt, geht in  $w_2$  und  $w_3$  der Bereich für  $x_i < 4$  stärker ein.

Es kommt hierbei nicht auf die absoluten Werte der  $w(x_i)$  an, sondern nur

auf die Form der Kurve, auf der die  $w(x_i)$  liegen. Dies ist die zweite wichtige Eigenschaft (II) von Gleichung (20).

Das alleinige Auftreten von  $\sum_{x_i \in \mathbb{D}} w(x_i)$  im Nenner von Gleichung (20) motiviert die Normierung der  $w(x_i)$  so, daß

$$\sum_{x_i} w(x_i) = 1 \quad \forall x_i \in \mathbb{D} \quad (21)$$

gilt. Wegen Eigenschaft (II) hat dies keinen Einfluß auf die gewichtete Mittelwertbildung. Man gewinnt auf diese Weise den Vorteil, daß die Division durch 1 in Gleichung (20) entfallen kann.

Der Term zur Bildung der gewichteten Mittelwerte vereinfacht sich also zu

$$\tilde{m} := \sum w_N(x_i) m(x_i) \quad \forall x_i \in \mathbb{D} . \quad (22)$$

Die Normierung der Gewichte ist somit keine unumgängliche Notwendigkeit; sie wirkt sich lediglich günstig bei der numerischen Simulation aus.

## 4.2 Instantiierte Neuronale Felder (INF)

In diesem Abschnitt werden die verwendeten Instantiierten Neuronalen Felder vorgestellt, die in dieser Arbeit zum Einsatz kommen.

Im Unterschied zu den Neuronalen Netzen, bei denen die Daten einer Eingabeschicht durch das Netz in eine Ausgabeschicht abgebildet werden, besteht ein Neuronales Feld nur aus einer einzigen Neuronenebene. Eine ggf. formal vorgeschaltete Eingabeschicht enthält somit nur die unverarbeiteten Eingabedaten.




Abbildung 21: Projektion der Datenpunkte auf das Neuronale Feld

An jedem Gitterpunkt in der oberen Schicht liegt ein Meßpunkt. Jeder Meßpunkt liefert über die drei Sensoren genau je einen Meßwert. Auf jedem Gitterpunkt des unteren Feldes befindet sich ein Neuron. Jedes Neuron des Feldes erhält also **drei** Meßwerte zu **einem** Meßpunkt. Die Reaktion des Feldes besteht nun in der kollektiven Zustandsänderung aller Neuronen.

Zur besseren Übersicht soll die Schicht mit den Eingabedaten im folgenden nur dann noch dargestellt werden, wenn es unbedingt erforderlich ist.

Wie man bereits erkennen kann, verwendet das hier benutzte Modell in seinem Neuronalen Feld genauso viele Neuronen, wie es Datenpunkte in der Eingabeschicht gibt.

Da die hier untersuchten Meßwertverteilungen zweidimensional angeordnet sind, erscheint die zweidimensionale Topologie der Netzstruktur sinnvoll. Das hier verwendete Neuronale Feld besteht somit aus einer Gitterstruktur (vergl. Abb. 22), wobei dessen Gitterpunkte genauso verteilt sind wie die Orte der Meßpunkte.

In der Literatur (z. B. [3]) finden sich verschiedene Beispiele für die Repräsentation zweidimensionaler Daten in Neuronalen Feldern.

Die Information wird in allgemeinen Neuronalen Feldern dabei durch eine Hilfsvariable  $U(\vec{x})$  repräsentiert, die auch *Felderregung* genannt wird.  $U(\vec{x})$  bezeichnet dabei nicht die Information direkt, sondern den Informationsgehalt am Ort  $\vec{x}$ . Die Information selbst wird in der Koordinate  $\vec{x}$  codiert. Mit anderen Worten,  $U(\vec{x}) \neq 0$  bedeutet, daß die Koordinate  $\vec{x}$  gegenüber

anderen Orten mit  $U(\vec{x}) = 0$  hervorgehoben wird, indem über diesem Ort  $\vec{x}$  Information vorhanden ist.

Aus diesem Grunde muß jede Größe, über die Information vorhanden ist, als eigene Felddimension dargestellt werden. Im vorliegenden Fall würde ein dreidimensionales Feld  $U(x, y, d)$  über dem Ortsraum und dem Dickenwert benötigt.  $U(x_0, y_0, d_0) \neq 0$  würde also bedeuten, daß am Ort  $(x_0, y_0)$  eine Dicke  $d_0$  vorliegt. Mit diesem Konzept kann man insbesondere auch darstellen, daß mehrere Dicken an einem Ort vorliegen oder auch daß an einem Ort überhaupt keine Dicke vorhanden ist ( $U(x_0, y_0, d) = 0 \forall d \in \mathbb{R}$ ). Der letztgenannte Fall ist wohlgermerkt verschieden von der Aussage, daß eine Dicke  $d_0 = 0$  vorliegt. Dieser Fall würde ja durch  $U(x_0, y_0, d_0 = 0) \neq 0$  angezeigt.

Mit steigender Dimensionszahl des Informationsraumes erfordert die Berechnung der Aktivitätsverteilung einen überproportional anwachsenden Rechenaufwand, da zur Bestimmung der Wechselwirkung mathematisch eine Faltung über alle Orte des Feldes durchgeführt werden muß.

Im Falle der vorliegenden Arbeit kann man diesen 3-D-Informationsraum  $(x, y, d)$  aber auf einen zweidimensionalen Raum reduzieren, wenn man berücksichtigt, daß durch das Feld eine reale physikalische Größe dargestellt werden soll: an einem Ort  $(x, y)$  kann nur genau ein Dickenwert der Ölschicht vorliegen. Der Informationsgehalt spielt hier also keine Rolle, da der Fall, daß über einem Ort mehrere oder gar keine Dicken spezifiziert sind, nicht auftreten kann.

Aus dem allgemeinen Neuronalen Feld wird hierdurch ein sog. *Instantiiertes Neuronales Feld (INF)*. Die Felderregung  $U(x, y)$  wird dabei direkt als Maß für die Dicke am Ort  $(x, y)$  benutzt.




Abbildung 22: Neuronen auf ihren festen Gitterplätzen

Jedes einzelne Neuron nimmt nun – den Meßwerten entsprechend – einen bestimmten Zustand (Erregungswert) an, der der vermuteten Öldicke an seiner Position entspricht. In der zeichnerischen Darstellung kann man das leicht dadurch verdeutlichen, daß man den Aktivitätszustand jedes Neurons auf der vertikalen Achse über jedem Gitterpunkt darstellt.





Abbildung 23: INF im angeregten Zustand

In den Feldern, die in dieser Arbeit verwendet werden, empfangen die Neuronen ihre Eingabeinformation jedoch nicht nur aus der Eingabeschicht (Sensoren), sondern sie interagieren außerdem auch noch mit ihren Nachbarn.



Erst durch diese Auswertung der Nachbarschaftszustände erhält das Neuronale Feld seine besonderen Eigenschaften<sup>16</sup>.

Abbildung 24: Ein einzelnes Neuron empfängt seine Reize von (vielen) Sensoren und seinen Nachbarn

Im Anschluß an diesen kurzen Überblick über den verwendeten Feldtyp soll nun näher auf die eigentliche Sensorfusion eingegangen werden. Hierbei interessiert speziell die Frage, wie die Fusion der Sensordaten durch die Feldstruktur erfolgt. Zuvor muß allerdings noch ein Gütemaß für die Verarbeitungsleistung eines INFs definiert werden.

### 4.3 Metrik zur Bewertung eines INF

Um die Qualität eines Neuronalen Feldes bei der Meßwertverarbeitung beurteilen zu können, muß in der Simulation die Ausgabe des INFs mit den Eingabedaten vor der Störungskette verglichen werden.

Für diesen Vergleich benötigt man ein Fehlermaß, dessen numerischer Wert die "Verschiedenartigkeit" der Ausgabedaten (*IST*-Werte) von den ungestörten Originaldaten beschreibt, die am Eingang hineingegeben wurden (*SOLL*-Werte).

<sup>16</sup>Ohne diese Interaktion bekommt man nur ein vorwärtsgekoppeltes Netzwerk.

Der so gefundenen "Fehler" hängt also einerseits von den Parametern der Störungskette ab, andererseits von der Qualität des INFs. Um zu verwertbaren Aussagen zu kommen, sollte man daher nicht gleichzeitig die Parameter vom INF und der Störungskette verändern.

In Abbildung (25) ist zunächst der Datensatz eines Sensors *vor* und *hinter* der Störungskette dargestellt<sup>17</sup>.

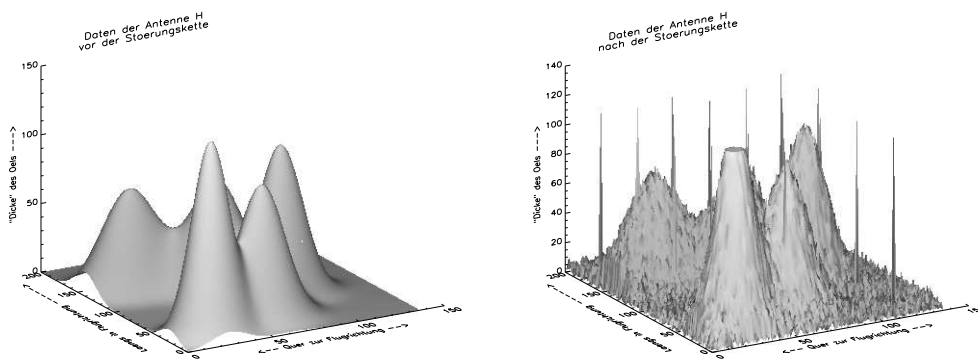


Abbildung 25: Auswirkung der Störungskette

Die Bilder zeigen jeweils die simulierte Ölverteilung über die gesamte Meßfläche, d.h. längs und quer zur Flugrichtung des (hier nur virtuellen) Meßflugzeuges.

In Abbildung (25), linkes Bild, erkennt man einige wesentliche Eigenschaften der Daten:

- Die Oberfläche ist glatt.
- An den Rändern fallen die Meßwerte gegen Null.
- Alle Werte sind positiv.

---

<sup>17</sup>Parametersatz: s. Abbildungsverzeichnis ab Seite 149

Die rechte Darstellung in Abbildung (25) enthält zusätzlich Störungen, die während einer realen Messung auftreten können:

- Die Oberfläche ist nicht mehr glatt, sondern verrauscht.
- Die Meßwerte erscheinen zum Teil oben gekappt (Sättigung).
- Es treten hohe Spikes auf.
- In den Randbereichen dominiert das Rauschen.

Die Definition einer geeigneten Fehlermetrik hängt naturgemäß von den erwünschten und unerwünschten Ähnlichkeiten der beiden Graphen ab. Zunächst kann man einfach den mittleren quadratischen Fehler MSE<sup>18</sup> (vergl. [4]) bestimmen, d.h.

$$\epsilon_{MSE} := \frac{1}{N_M} \sum_{\forall(x,y)} (m_{in}(x,y) - m_{out}(x,y))^2 . \quad (23)$$

Darin ist  $N_M$  die Anzahl der Meßpunkte,  $m_{in}$  und  $m_{out}$  sind je eine Verteilung. Das Kriterium ist hier der Abstand der einzelnen Punkte beider Verteilungen. Für Abbildung (25) erhält man so  $\epsilon_{MSE} = 24,54$ .

Bei praktischen Messungen steht die ideale Verteilung  $m_{in}$  nicht zur Verfügung; die Bestimmung des Fehlermaßes  $\epsilon_{MSE}$  ist daher nicht möglich. Für die vorliegenden realen Meßdaten ist aber das Gesamtvolumen  $V_{in}$  des ausgebrachten Öls bekannt.

Man kann daher das Volumen  $V_{out}$  der Verteilung  $m_{out}$  und dessen Verhältnis zu  $V_{in}$  bestimmen.

Die Volumenbestimmung erfolgt als Integral der Meßwerte über die Grundfläche, d.h.

$$V = \int_y \int_x m(x,y) \, dx \, dy . \quad (24)$$

---

<sup>18</sup>Mean Squared Error

Da hier nur auf diskreten Meßpunkten im Einheitsraster gearbeitet wird, erhält man

$$V = \sum_{\forall y} \sum_{\forall x} m(x, y) . \quad (25)$$

Zu den beiden Graphen in Abbildung (25) erhält man

$$V_{in} = 493876,53 \quad V_{out} = 582730,37 . \quad (26)$$

Mit der Definition

$$\epsilon_V := \frac{V_{out}}{V_{in}} \quad (27)$$

bekommt man so einen Fehlerkennwert von  $\epsilon_V = 1,1799$ , was einem Volumenfehler von rund + 18 % entspricht.

Der Fehlerkennwert  $\epsilon_{MSE}$  unterscheidet sich analytisch vor allem dadurch von  $\epsilon_V$ , daß das Quadrat in Gleichung (23) verhindert, daß sich Differenzen zwischen  $m_{in}$  und  $m_{out}$  gegenseitig herausmitteln können.

In diesem Sinne ist  $\epsilon_{MSE}$  das strengere Fehlermaß.

Mit den beiden Kennwerten  $\epsilon_{MSE}$  und  $\epsilon_V$  kann man nun beurteilen, in welchem Maße ein INF die simulierten Störungen reduziert, mit denen die Daten innerhalb der Störungskette beaufschlagt wurden.

#### 4.4 Eliminierung von "Ausreißern"

Bei der simultanen Messung einer realen physikalischen Größe sind die einzelnen Sensoren der Meßeinrichtung in der Regel alle möglichst gut, aber dennoch unterschiedlich, kalibriert.

Wird nun eine Messung durchgeführt, so erhält man bei  $N$  Sensoren auch  $N$  Meßwerte  $m_i$ , die normalerweise alle um einen Mittelwert herum streuen.

Die übliche Vorgehensweise zur näherungsweisen Bestimmung des tatsächlichen Wertes der gemessenen Größe ist deshalb die Mittelung

$$\bar{m} = \frac{1}{N} \sum_{i=1}^N m_i . \quad (28)$$

Dieses Verfahren zur Schätzung des realen Wertes der Meßgröße hat jedoch den gravierenden Nachteil, daß "Ausreißer" nicht automatisch erkannt und eliminiert werden können. Solche Störungen sind in einfachen Fällen stochastisch allen Meßwerten überlagert<sup>19</sup>. Normalerweise mitteln sie sich daher gegenseitig heraus, wenn über zahlreiche  $m_i$  summiert wird.

Andererseits ist aber auch der Fall denkbar, daß ein Sensor völlig ausfällt und er somit ständig einen konstanten, aber falschen Wert liefert. Ein Fehler dieses Typs macht meistens die gesamte Messung unbrauchbar.

An dieser Stelle verspricht nun der Einsatz einer neuronalen Dynamik eine entscheidende Verbesserung.

Die nachfolgende Abbildung (26) auf der folgenden Seite zeigt drei Meßwerte  $m_1 \dots m_3$ . Außerdem ist der tatsächliche Wert  $m_0$  markiert.

---

<sup>19</sup>In der Regel lassen sich diese Störungen durch ein stationäres, mittelwertfreies, weißes Rauschen beschreiben.




Abbildung 26: Meßwerte und Attraktoren

An der Lage<sup>20</sup> der Meßwerte auf der Abszisse (Anregungsachse) kann man bereits erkennen, daß der Sensor von  $m_3$  den besten Meßwert geliefert hat, da er am nächsten beim tatsächlichen Wert  $m_0$  liegt.

Die Abweichung des Meßwertes  $m_2$  vom exakten Wert ist ebenfalls noch relativ gering,  $m_1$  ist jedoch deutlich zu klein.

Von jedem einzelnen Wert  $m_i$  ist weiterhin bekannt, daß er in einem gewissen Intervall streut. Dies ist nicht nur eine Eigenschaft des jeweiligen Sensors, sondern liegt im Meßvorgang selbst begründet. Wenn also ein Wert  $m_i$  gemessen wird, dann soll je nach Meßgenauigkeit der wirkliche Wert  $m_{i,0}$  gaußverteilt in einem Intervall  $[m_{i,0} - \delta_m ; m_{i,0} + \delta_m]$  liegen.

Diese Verteilung ist in Abbildung (26) allerdings nicht dargestellt. Es ist aber leicht vorstellbar, daß jeder Meßwert  $m_i$  in einem kleinen Bereich horizontal schwankt. Diese Schwankung wäre dann ihrerseits normalverteilt.

<sup>20</sup>Gegenüber Abbildung (25) von Seite 42 ist hier aus dem gesamten Meßfeld nur die Erregung eines einzelnen Meßpunktes dargestellt. Die horizontale Achse von Abbildung (26) entspricht der vertikalen Erregungsachse in Abbildung (25).

#### 4.4.1 Einführung einer neuronalen Dynamik

Man kann nun eine neuronale Dynamik benutzen, um den wahren Wert  $m_0$  möglichst genau aus den Meßwerten  $m_i$  zu bestimmen. Man wählt hierzu zunächst einen beliebigen<sup>21</sup> Startwert  $m$ , der arithmetische Mittelwert  $\bar{m}$  der Sensoren ist hierbei meist eine brauchbare Wahl (vergl. Gleichung (28)).

Der Wert  $m$  wird nun als Stärke der Erregung eines einzelnen Neurons interpretiert. Mit diesem  $m$  kann man eine Regel definieren, die iterativ  $m$  variiert, bis der Wert schließlich einen Fixpunkt ( $\dot{m} = 0$ ) der Regel erreicht.

Die Regel selbst stellt sich in kontinuierlicher Form als explizite, gewöhnliche, nichtlineare Differentialgleichung erster Ordnung dar.

Für die weitere Untersuchung wird folgende DGL als Iterationsregel **I.1** definiert:

$$\dot{m} = \frac{1}{\tau} \cdot \sum_i (m_i - m) \cdot e^{-\frac{(m_i - m)^2}{2\sigma_i^2}} \quad (29)$$

$\dot{m}$  ist dabei die Änderung der Erregung  $m$ , die nach jedem Schritt erfolgt.  $(m_i - m)$  ist der Abstand des berechneten  $m$  gegenüber dem Meßwert  $m_i$  (vom Sensor der Nummer  $i$ ).

Der Exponentialterm dämpft schließlich den Einfluß von Ausreißern auf den Wert von  $m$ :

Liegt  $m$  nahe bei einem  $m_i$ , so hat die Exponentialfunktion in diesem Bereich einen großen Wert. Damit unterliegt  $m$  einer starken Anziehung in Richtung  $m_i$ . Die  $m_i$ -Werte bezeichnet man deshalb auch als *Attraktoren*. Für  $m > m_i$  ist  $\dot{m} < 0$ , was zu einer Verkleinerung von  $m$  führt. Entsprechend führt im Fall  $m < m_i$  der Wert  $\dot{m} > 0$  zu einer Verschiebung von  $m$  zu größeren Werten hin.

---

<sup>21</sup>Eine detailliertere Diskussion der Wahl des Startwertes folgt in Abschnitt 5.4.




Abbildung 27: Reichweiten der Attraktoren

Die  $\sigma_i$ -Werte charakterisieren die Wirkungsreichweite der einzelnen Attraktoren. Typischerweise wählt man sie alle gleich:  $\sigma_A := \sigma_1 = \sigma_2 = \sigma_3$ . Im folgenden wird daher nur noch  $\sigma_A$  verwendet<sup>22</sup>.




Abbildung 28: Phasendiagramm (dick durchgezogene Kurve) zu Gleichung (29) (Regel I.1) und Abbildung (27). Die drei Attraktorpositionen ( $m_1, m_2, m_3$ ) sind durch vertikale Linien markiert, der exakte Wert  $m_0$  punktiert. Für den rechten Attraktor sind zusätzlich dessen beide Einzelkomponenten dargestellt.

Die besondere Eigenschaft des dynamischen Systems nach Gleichung (29), Regel I.1, ist, daß es selbsttätig eine Entscheidung fällt: überlappen sich die Wirkungsbereiche zweier oder mehrerer Meßwerte (Abbildung (27),  $m_3$  mit

<sup>22</sup>Der Index  $A$  steht dabei einfach für *Antenne*.

$m_2$ ; Abbildung (28), rechte Seite), so entsteht *ein* gemeinsamer Attraktor *zwischen* den Einzelmeßwerten. Die Systemvariable  $m$  würde dann, wenn sich ihr Wert ebenfalls innerhalb der Reichweite  $\sigma_A$  befindet, in diesen gemittelten Attraktor relaxieren. Das System würde in diesem Fall also eine Mittelung zwischen ähnlichen, sich überlappenden Meßwerten durchführen.

Überlappen die Einzelattraktoren bei sehr verschiedenen Meßwerten jedoch nicht, so hat das dynamische System mehrere einzelne Fixpunkte (Abbildung (28): zwei Attraktoren). Die Systemvariable  $m$  wird dann zu dem Attraktor gezogen, in dessen Wirkungsbereich  $\sigma_A$  sie liegt. In diesem Fall würde also keine Mittelung zwischen *allen* Meßwerten eintreten, sondern das System würde sich für einen der gebildeten Attraktoren entscheiden.

Welcher Fall letztlich eintritt, hängt einerseits vom Startwert der Variablen  $m$  (hier  $\bar{m}$ ) ab, andererseits natürlich von der Größe des Wirkungsbereiches, der für einen aus mehreren ähnlichen Meßwerten gebildeten Attraktor entsprechend größer ist (Abbildung (28), rechter Attraktor).

Insgesamt wird sich der Systemzustand also bei einem Wert von  $m$  stabilisieren, der möglichst nahe am Startwert liegt und für den möglichst viele Meßwerte votieren.

Im dargestellten Fall stellt sich für  $m$  ein Wert in der Mitte zwischen  $m_2$  und  $m_3$  ein. Damit wird eine sehr gute Approximation des wahren Wertes  $m_0$  erreicht.

Gleichzeitig wird der Ausreißer  $m_1$  fast völlig aus der Berechnung eliminiert, da er bei seiner großen Entfernung  $|m_1 - m|$  unter Berücksichtigung der Reichweite seiner Exponentialfunktion keinen Einfluß mehr auf die Berechnung von  $m$  haben kann.

Die Geschwindigkeit der Konvergenz zum Fixpunkt ist über den Parameter  $\tau$

einstellbar. Die Verzögerung  $\tau$  wird zunächst als hinreichend groß angenommen ( $\frac{1}{\tau}$  entsprechend klein), so daß sich der Wert von  $m$  nicht allzu schnell ändert<sup>23</sup>.

#### 4.4.2 Sensorfusion ohne Nachbarschafts-Wechselwirkung

Zunächst soll untersucht werden, ob und wie stark sich die Meßergebnisse verbessern, wenn man die Dynamik der Iterationsregel **I.1** aus dem vorangegangenen Abschnitt zur Elimination von unkorrelierten Ausreißern benutzt. Unter unkorrelierten Ausreißern werden hier solche verstanden, die nicht simultan auf allen drei Kanälen gleichzeitig auftreten.

$$\dot{m} = \frac{1}{\tau} \cdot \sum_{i=1}^3 (m_i - m) \cdot e^{-\frac{(m_i - m)^2}{2\sigma_A^2}} \quad (30)$$

Zur besseren Demonstration wurden die Parameter der Störungskette so gewählt, daß der H-Kanal mit 20% Rauschen beaufschlagt wurde, während die M- und L-Kanäle nur 1% additives Rauschen enthalten.

Obwohl die DGL aus Gleichung (30) relativ unkompliziert ist, wird sie hier nicht analytisch gelöst, sondern numerisch.

Zur Simulation muß die DGL daher diskretisiert werden. Beginnend mit einem Startwert  $\bar{m}$  wird jeweils der rechte Teil von Gleichung (30) ausgewertet. Anschließend wird

$$m_{neu} := m_{alt} + \dot{m}_{alt} \quad (31)$$

berechnet. Wenn  $\dot{m} = 0$  wird, hat man einen Fixpunkt erreicht. Der gefundene Wert für  $m$  ist dann eine stabile Lösung der DGL.

Das beschriebene Iterationsverfahren wird nun auf alle Punkte des Meßfeldes *unabhängig* angewendet.

---

<sup>23</sup>Dieser Parameter wird in Abschnitt 5.1 diskutiert.




Abbildung 29: Simulierte Eingangsverteilung ohne Störungen




Abbildung 30: Eingangsdaten mit Störungen. Links der H-Kanal mit 20% Rauschen, daneben die M- und L-Kanäle mit je 1% Rauschen.

Die Bilder auf der folgende Seite zeigen die Antwort des INFs. Hierbei gibt das obere Bild die Startwerte des INFs wieder, die sich durch Mittelung der H-, M- und L-Kanäle ergeben. Das untere Bild zeigt den Zustand des INFs nach rund 340 Iterationsschritten.




Abbildung 31: Meßdaten als arithmetische Mittelwerte der drei Kanäle  
aus Abbildung (30):  $\epsilon_{MSE} = 757,71$  und  $\epsilon_V = 2,201$




Abbildung 32: Wirkung von **I.1**:  
 $\epsilon_{MSE} = 17,37$  und  $\epsilon_V = 1,074$  nach 340 Iterationen

In den Bildern erkennt man eine deutliche qualitative Verbesserung, die sich auch in den Ähnlichkeitsmaßen  $\epsilon_{MSR}$  und  $\epsilon_V$  zeigt.

Wenn allerdings die M- und L-Kanäle ebenfalls mit einem entsprechend starken Rauschen 'verunreinigt' werden, verschlechtert sich das Resultat wieder deutlich.

(Dies ist sicherlich zu erwarten: bei starkem Rauschen auf allen Kanälen kann man keine Mehrheitsentscheidung von verlässlichen Werten mehr bilden. Es kommen dann mehr oder minder zufällige Majoritäten zustande.)

Das vorgestellte Verfahren erlaubt – in gewissen Grenzen – sogar die Korrektur von Offsetfehlern, solange diese nur in einer Minderheit der Kanäle auftreten.

#### 4.5 Gewichtung der Meßkanäle mit Vertrauensfaktoren

Die gefundene Verbesserung der Sensordaten motiviert eine Erweiterung der I.1-Regel um einen "Vertrauens"-Faktor  $\vartheta$ :

Im nebenstehenden Bild scheint es ratsam, dem Meßwert  $m_3$  prinzipiell mehr zu vertrauen als  $m_1$ , da letzterer weiter vom wahren Wert  $m_0$  entfernt liegt.




Abbildung 33: Meßwerte und Attraktoren

Man kann dies dadurch implementieren, daß man die Stärke des Attraktors von  $m_3$  (Abbildung (33), violett) gegenüber  $m_1$  (Abbildung (33), rot) durch eine entsprechende Veränderung des Verhältnisses  $\vartheta_3 : \vartheta_1$  erhöht.

Die Iterationsregel **I.1** wird deshalb zu **I. $\vartheta$**  erweitert:

$$\dot{m}(\vec{r}) = \frac{1}{\tau} \cdot \sum_{i=1}^3 \vartheta_i(\vec{r}) (m_i(\vec{r}) - m(\vec{r})) \cdot e^{-\frac{(m_i(\vec{r}) - m(\vec{r}))^2}{2\sigma_A^2}}. \quad (32)$$

Zu jedem Meßkanal (Index  $i$ ) gibt es nun einen Vertrauensfaktor  $\vartheta_i$ . Der Vertrauensfaktor ist zudem ortsabhängig (daher  $\vartheta_i(\vec{r})$ ). Man kann allerdings im voraus nicht genau wissen, wie hoch das Vertrauen in den jeweiligen Meßkanal und am jeweiligen Ort ist. Die  $\vartheta_i$  werden deshalb so definiert, daß das INFs sie selbständig erlernt:

- Zuerst werden alle  $\vartheta_i$  mit 0,5 initialisiert (50 % Vertrauen).

Nachdem das INF in einen Fixpunkt relaxiert ist, wird der Vertrauensfaktor um 1 % variiert:

- $\vartheta_i(\vec{r})_{t+1} = 1,01 \cdot \vartheta_i(\vec{r})_t$ ,  
wenn  $m_i$  der nächste Nachbar von  $m$  (dem Feldzustand) ist, oder
- $\vartheta_i(\vec{r})_{t+1} = 0,99 \cdot \vartheta_i(\vec{r})_t$ ,  
wenn  $m_i$  die größte Entfernung aller  $m_i$  von  $m$  hat.

Anschließend wird das INF erneut mit den gleichen Startwerten initialisiert und die Berechnung wiederholt.

Damit ein Kanal die übrigen nicht irgendwann völlig dominiert, werden die  $\vartheta_i$  auf das Intervall

$$\vartheta_i \in [0,01 ; 1,99] \quad (33)$$

begrenzt. Dennoch darf man die  $\vartheta_i$  nicht zu schnell ändern, weil das INF sonst nicht mehr in einen stabilen Zustand konvergiert. Es ist daher in der Regel sinnvoll, zunächst alle  $\vartheta_i$  gleich zu wählen und sie erst neu zu besetzen, wenn sich die Werte im INF pro Iterationsschritt nicht mehr stark ändern (d. h. das INF hat einen Fixpunkt erreicht).

Die letzte Forderung bedeutet, daß sichergestellt wird, daß die Felderregung  $m(\vec{r})$  wesentlich schneller relaxiert, als sich die  $\vartheta_i$ -Faktoren ändern (Zeitskalen-Separation).

Man kann außerdem  $\vartheta_i = \vartheta_i(m, \dots)$  meßwertabhängig wählen, falls etwa einer der Sensoren für große Meßwerte  $m$  generell bessere Werte liefert als für kleine.




Abbildung 34: Zur Wahl der  $\vartheta_i$  bei drei unterschiedlichen Sensoren.

Abbildung (34) zeigt eine mögliche Wahl der dickenabhängigen  $\vartheta_i$ . Die rote Kurve für  $\vartheta_1$  gehört zu einem Sensor, der bei kleinen  $m$ -Werten besonders gute Ergebnisse liefert. In diesem Bereich wird er daher gegenüber den anderen Kanälen stärker gewichtet. Bei mittleren und großen Meßwerten sind die Werte des ersten Sensors jedoch so schlecht, daß man ihnen nur sehr wenig vertraut.

Die grüne Kurve beschreibt eine Gewichtung für einen Sensor, von dem man vor allem im mittleren Meßwertbereich gute Ergebnisse erwartet.

Die violette Kurve gehört zu einem Sensor, der zur Erfassung großer Meßwer-

te genutzt werden soll. In den übrigen Meßbereichen liefert er – verglichen mit den anderen beiden Sensoren – zwar noch nutzbare, aber z. B. nicht so genaue Meßwerte.

Die Gewichtungsfunktionen in Abhängigkeit vom Wert  $m$  der gemessenen Größe kann das Feld ebenfalls selbständig erlernen.

Der entscheidende Gesichtspunkt bei der Einführung der  $\vartheta_i(m, \vec{r})$  ist, daß die wirklichen Werte  $m_0$  zur Bestimmung der  $\vartheta_i(m, \vec{r})$  nicht bekannt sein müssen.

Das INF lernt die  $\vartheta_i(m, \vec{r})$  somit selbständig (unüberwacht). Die einzige Annahme, die hierzu gemacht werden muß, ist, daß ein stabiler Feldzustand des INFs dem wirklichen Wert  $m_0$  näher kommt, als der Startwert  $m$  vor Beginn der Iterationen.

Die Diskussion der  $\vartheta_i$ -Bestimmung soll an dieser Stelle nicht weiter fortgeführt werden. Stattdessen soll nun eine Verbesserung vorgestellt werden, die zu einer erheblichen Erhöhung der Feldqualität führt.

## 4.6 INF mit Ortswechselwirkungen

### 4.6.1 Prinzip

Wenn man aus der zweidimensionalen Meßwertverteilung der Temperatur eines Ölfleckens eine einzelne Zeile isoliert, dann erhält man für jeden Sensor etwa das folgende Bild:




Abbildung 35: Eine einzelne Zeile (Scanline): Meßsignal mit Störungen (schwarz) und idealer Verlauf (rot)

In Abbildung (35) erkennt man im Meßsignal deutlich die nadelförmigen Spikes. Das Vorhandensein derartiger Spikes stellt ein besonderes Problem bei der Meßdatenverarbeitung mit klassischen Verfahren dar, da diese Verfahren solche Ausreißer nicht erkennen können.

Die Skizze motiviert jedoch folgende Überlegung: wenn jedes Neuron nicht nur auf seine eigenen Meßdaten schaut, sondern auch mitberücksichtigt, was die Neuronen in seiner unmittelbaren Nachbarschaft festgestellt haben, dann sollten isolierte Signalspitzen genauso verschwinden, wie ein größerer Teil des Rauschens.

Dieses Vorgehen wird im folgenden als *Nachbarschafts-Interaktion* bezeichnet.

### 4.6.2 Realisierung als Iterationsterm

Jedes Neuron des INFs soll über die Resultate seiner Nachbarn mitteln. Auch hier soll wieder ein Attraktor-Approximationsverfahren verwendet werden, wie es bereits in Abschnitt (4.4) vorgestellt wurde.

Diesmal werden jedoch nicht die Meßsignale mehrerer Sensoren fusioniert, sondern es wird der aktuelle Erregungszustand des Neurons mit den Nachbarneuronen zusammengefaßt.


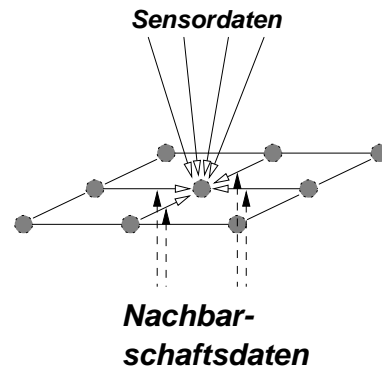


Abbildung 36: Definition von  $r_N$

Zunächst muß geklärt werden, welche Neuronen grundsätzlich als Nachbarn angesehen werden sollen, d. h. welche Nachbarneuronen überhaupt einen Einfluß auf den Zustand des Mittelpunktneurons haben sollen.

Man definiert sich hierzu einen Radius  $r_N$ . Alle Neuronen innerhalb von  $r_N$  werden dann als Nachbarn<sup>24</sup> betrachtet. In dieser Arbeit wird  $r_N$  so gewählt, daß jeweils rund 50 Neuronen berücksichtigt werden.

Zusätzlich zum Nachbarschaftsradius sollte eine Gewichtung eingeführt werden: weiter entfernte Neuronen sollten dadurch einen geringeren Einfluß auf das Ergebnis haben als näher in der Mitte liegende.

Für die Wahl der Gewichtung der Nachbarschaftswerte gibt es zahlreiche Möglichkeiten. Einige Beispiele sind in der folgenden Abbildung (37) dargestellt. In dieser Arbeit wird mit einer Cosinusgewichtung gearbeitet, deren

<sup>24</sup>Der Index  $N$  bezeichnet im folgenden jeweils Größen, die mit der Nachbarschaftswirkung zu tun haben.

Form der Funktion auf der linken Seite von Abbildung (37) ähnelt. Die Rechteckgewichtung in der Mitte ist für die numerischen Simulation günstig, da sie die erforderlichen Rechenschritte reduziert. Die Gewichtsfunktionen auf der rechten Seite von Abbildung (37) ist ein Beispiel für eine Funktion mit negativen Abschnitten, deren besondere Eigenschaften hier nicht weiter untersucht werden.




Abbildung 37: Verschiedene Gewichtsfunktionen für den Nachbarschaftseinfluß

Mathematisch bedeutet die Nachbarschaftsbeziehung, daß man auf der Achse des vermuteten *wahren* Meßwertes  $m$  weitere Attraktoren erzeugt (vergl. Abb. 26). Hierzu fügt man einen weiteren Term zur Iterationsregel **I.1** hinzu. Zunächst sei

$$\mathbb{D} := \{ \text{die Menge aller Neuronen im Nachbarschaftsbereich } r_N, \quad (34) \\ \text{einschließlich des Neurons in der Mitte. } \}$$

Das Mittelpunktsneuron befinde sich am Aufpunkt  $\vec{r}$ . Mit  $\vec{r}_k$  sind jeweils die Orte der einzelnen Nachbarn relativ zu den Koordinaten des Mittelpunktsneurons definiert.

Mit diesen Definitionen gilt nun als Nachbarschaftsterm

$$N(\vec{r}) = \frac{1}{\tau} \sum_{\forall \vec{r}_k \in \mathbf{D}} g(\vec{r}_k) \cdot (m(\vec{r} + \vec{r}_k) - m(\vec{r})) \cdot e^{-\frac{(m(\vec{r} + \vec{r}_k) - m(\vec{r}))^2}{2\sigma_N^2}} \quad (35)$$

- $N(\vec{r})$  beschreibt die Änderung von  $m(\vec{r})$  infolge der Nachbarschaftswerte von  $m(\vec{r})$ .
- $g(\vec{r}_k)$  ist eine der Nachbarschafts–Gewichtungsfunktionen, die in Abbildung (37) dargestellt sind. Es handelt sich hier also nicht um einen ”Vertrauensfaktor”.  $g(\vec{r}_k)$  ist daher auch nicht mit den  $\vartheta_i$  in der Iterationsregel **I.1** vergleichbar.
- Durch die Exponentialfunktion wird der Einfluß von stark abweichenden  $m$ –Werten in der Nachbarschaft vermindert bzw. unterdrückt<sup>25</sup>.

Während sich also  $g(\vec{r}_k)$  auf die räumliche Umgebung des Mittelpunktneurons bezieht, entscheidet die Exponentialfunktion in Abhängigkeit vom Betrag der Meßgröße  $m$  nur darüber, wie stark der jeweilige Umgebungswert überhaupt berücksichtigt wird.

### 4.6.3 Erweiterung der Iterationsregel

Der gefundene Term  $N(\vec{r})$  wird nun zu der in Abschnitt (4.4) dargestellten Iterationsregel **I.1** hinzugefügt. Auf diese Weise ergibt sich eine neue Iterationsregel, die sowohl einen Term für den sensorischen Input, als auch einen Term für die Nachbarschaftswechselwirkung enthält.

---

<sup>25</sup>vergl. Abschnitt 4.4 auf Seite 44.

Man erhält die Iterationsregel **I.2**:

$$\begin{aligned} \tau \cdot \dot{m}(\vec{r}) = & \eta_A \sum_{i=1}^3 (m_i(\vec{r}) - m(\vec{r})) \cdot e^{-\frac{(m_i(\vec{r}) - m(\vec{r}))^2}{2\sigma_A^2}} \\ & + \eta_N \sum_{\forall \vec{r}_k \in \mathbf{D}} g(\vec{r}_k) \cdot (m(\vec{r} + \vec{r}_k) - m(\vec{r})) \cdot e^{-\frac{(m(\vec{r} + \vec{r}_k) - m(\vec{r}))^2}{2\sigma_N^2}} \end{aligned} \quad (36)$$

Gleichung (36) beschreibt die Änderung des Erregungszustandes  $m(\vec{r})$  eines Neurons auf der Position  $\vec{r}$  im INF.

- Der obere Summenterm faßt die Meßwerte  $m_i$  der 3 Sensoren an Position  $\vec{r}$  zusammen.
- Der untere Summenterm berücksichtigt jetzt zusätzlich die Nachbarschaftsneuronen.
- Die Faktoren  $\eta_A$  und  $\eta_N$  gewichten die beiden Summen gegeneinander.
- Die Exponentialfunktionen bewirken in beiden Summen vor allem die Elimination von Ausreißern durch Variation der Attraktorreichweiten.
- Die  $m_i(\vec{r})$  und  $m(\vec{r} + \vec{r}_k)$  erzeugen alle Attraktoren auf der eindimensionalen Erregungsachse, auf der irgendwo ein Punkt liegt, der den *wahren* Meßwert  $m_0$  repräsentiert.
- Der Parameter  $\tau$  erlaubt eine Änderung der Zeitskala, auf der sich die Erregung  $m(\vec{r})$  verändert.

In Abhängigkeit von den gewählten Parametern  $\sigma_A$ ,  $\sigma_N$ ,  $\eta_A$ ,  $\eta_N$  und  $g(\vec{r})$  konvergiert typischerweise

$$\dot{m}(\vec{r}) \longrightarrow 0 \quad \text{und} \quad m(\vec{r}) \longrightarrow m'_0(\vec{r}) \approx m_0(\vec{r}) . \quad (37)$$

Hierbei ist  $m'_0$  der Attraktor der Iterationsregel, der den tatsächlichen Wert  $m_0$  repräsentieren soll.

Bei ungünstiger Wahl der Parameter kann es aber auch vorkommen, daß das INF keinen stabilen Fixpunkt erreicht. Ebenso treten Fälle auf, in denen die INF-Verteilung zwar stabil ist, sie jedoch nicht die reale Verteilung repräsentiert.

#### 4.6.4 Anmerkungen zur programmtechnischen Realisierung in IDL

Die Auswertung der Iterationsregel **I.2**, Gleichung (36), für alle Bildpunkte<sup>26</sup> erfordert einen nicht unerheblichen Rechenaufwand. Da die Iterationsregel außerdem in jedem Iterationsschritt komplett neu ausgewertet werden muß, lohnen sich einige Überlegungen zur Optimierung der Rechenzeit.

Die Laufzeit der INF-Software wächst linear mit der Anzahl der Meßpunkte und der Anzahl der durchgeführten Iterationsschritte. Sie wächst quadratisch mit steigendem Nachbarschaftsradius  $r_N$ .

Die komplette Simulation wurde in der Visualisierungs-Makrosprache **IDL**<sup>27</sup> realisiert. Bei IDL handelt es sich um eine Art *BASIC* oder Vektor-*FORTRAN*. Ausgeführt werden die Programme mit einem Interpreter, der auf Matrixverarbeitung und Datenvisualisierung spezialisiert ist. Zur Erzielung einer kurzen Laufzeit sollten deshalb möglichst viele Rechenschritte als Matrixoperationen formuliert werden.

Weiterhin sollten die Matrixgleichungen stets so umgeformt werden, daß statt zahlreicher Operationen mit kleinen Matrizen eher wenige Operationen mit entsprechend vergrößerten Matrizen auftreten.

---

<sup>26</sup>rund 27000 bei einer simulierten Meßfeldgröße von  $136 \times 200$ , etwa 82000 bei den realen Meßfeldgrößen

<sup>27</sup>Interactive Data Language, Literatur: [13], [14], [15]. IDL ist eine Batch-Sprache, mit der man bequem graphische Darstellungen erzeugen kann (z. B. die meisten Diagramme dieser Arbeit).

Ein komplettes IDL Programm<sup>28</sup> zur Simulation eines INFs nach Regel **I.2** befindet sich in Anhang C.

Die Struktur von Regel **I.2** ist außerdem sehr gut parallelisierbar, da sich die Werte im INF bei allen Neuronen synchron ändern. Prinzipiell könnte daher jedem Neuron ein eigener Prozessor zugeordnet werden (massive Parallelisierung).

Aufgrund dieser Eigenschaft kann fast jede vorhandene Multiprozessorarchitektur optimal ausgenutzt werden. Neben normalen Multiprozessor- Rechnern sind insbesondere auch Rechner geeignet, die nach dem SIMD (Single Instruction / Multiple Data) Prinzip arbeiten.

Da die Leistung von IDL Programmen durch den Einsatz mehrerer Prozessoren nicht skalierbar ist, ist hierzu eine Portierung, z. B. nach C, erforderlich.

---

<sup>28</sup>Das dort abgedruckte Listing ist noch nicht optimal: wenn man die äußere Schleife (über die rund 41000 Meßpunktkoordinaten) gegen die innere Schleife (über rund 80 Neuronen der Nachbarschaftsregion) austauscht, verkürzt sich die Gesamtrechenzeit bereits auf etwa ein Viertel, da sich dabei die Gesamtzahl der Matrixoperationen verringert.

#### 4.6.5 Experimente: Sensorfusion mit Wechselwirkungen

Eine mögliche Wahl für die Gewichtungsfunktion der Nachbarschaftsneuronen ist eine zweidimensionale Cosinusglocke. Eine solche Funktion kann durch

$$g_{\cos}(\vec{r}) := \frac{1}{C_{Norm}} \cdot \left[ \cos \left( |\vec{r}| \cdot \frac{\pi}{r_N} \right) + 1 \right] \quad (38)$$

beschrieben werden. Der Nachbarschaftsradius wird in der nachfolgenden Simulation zu  $r_N = 5$  gewählt.

Im Definitionsbereich von  $|\vec{r}| = [0, r_N]$  durchläuft die Cosinusfunktion einen Wertebereich von  $[-1, +1]$ . Durch die Verschiebung um  $+1$  und anschließende Normierung mit  $C_{Norm}$  erhält man  $g_{\cos}(\vec{r})$ . Die Symmetrie der Cosinusfunktion stellt sicher, daß die Gewichtungsfunktion isotrop<sup>29</sup> ist.

Die zusätzliche Normierung der Gewichtungsfunktion auf

$$\int_{-r_N}^{+r_N} \int_{-r_N}^{+r_N} g_{\cos}(\vec{r}) \, dx \, dy \stackrel{\text{hier}}{=} \sum_{|\vec{r}| \leq r_N} g_{\cos}(\vec{r}) \stackrel{!}{=} 1 \quad (39)$$

erweist sich später für die Bildung der gewichteten Mittelwerte als günstig (vergl. Abschnitt 4.1.4). Gleichung (39) liefert gleichzeitig den Normierungsfaktor  $C_{Norm}$  für Gleichung (38).

Die so gefundene Nachbarschafts–Gewichtungsfunktion  $g_{\cos}(\vec{r})$  ist in den Abbildungen (42) und (43) auf Seite 67 dargestellt. Man muß sich dort die Funktion allerdings noch in den Koordinatenursprung verschoben denken<sup>30</sup>.

---

<sup>29</sup>Die Nachbarschaftsgewichtung ist nicht richtungsabhängig.

<sup>30</sup>Isotrope Gewichtungsfunktionen sind immer rotationssymmetrisch; der Koordinatenursprung muß innerhalb der Rotationsachse liegen. Andere typische Beispiele für Gewichtungsfunktionen sind Kegel, Halbkugeln und Gaußglocken.

Mit der Iterationsregel **I.2** erhält man gegenüber **I.1** ein deutlich verbessertes Ergebnis. Die beiden folgenden Bilder (Abb. 41 auf der folgenden Seite) geben den Zustand des INFs nach 98 Iterationsschritten wieder.

Hier zunächst die Inputdaten:




Abbildung 38: Simulierte Eingangsverteilung ohne Störungen




Abbildung 39: Eingangsdaten mit Störungen. Links der H-Kanal mit 20% Rauschen, daneben die M- und L-Kanäle mit je 3% Rauschen.




Abbildung 40: Startwerte mit 20 % Rauschen auf dem H-Kanal und nur 3 % Rauschen auf den anderen Kanälen:  $\epsilon_{MSE} = 757,71$  und  $\epsilon_V = 2,201$ .




Abbildung 41: Verbesserung durch die Nachbarschaftsinteraktion von **I.2**:

$$\epsilon_{MSE} = 9,84 \text{ und } \epsilon_V = 1,0687.$$

Die hier verwendete Nachbarschaftsgewichtung  $g_{\cos}(\vec{r})$  nach Gleichung (38) hat dabei für den Nachbarschaftsradius von  $r_N = 25$  folgendes Aussehen:




Abbildung 42: Verschobene Darstellung von Gleichung (38)

Man erkennt die Cosinusglocke etwas deutlicher in einem Schnitt entlang der Hauptdiagonalen  $x = y$ .

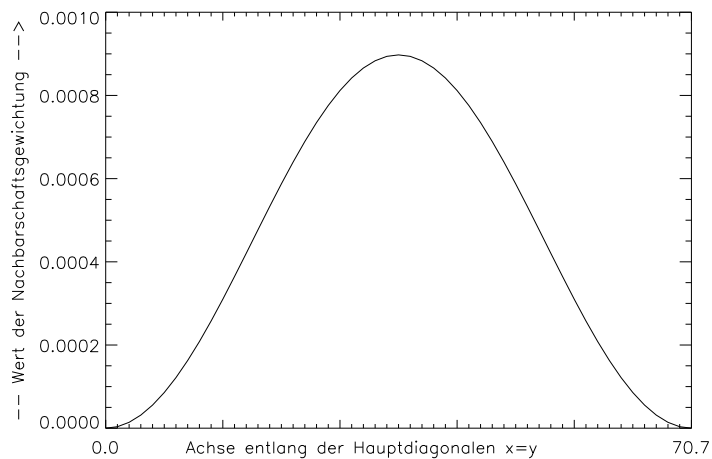


Abbildung 43: Verschobene Projektion von Gleichung (38). Die Zahlenwerte von  $g_{cos}(\vec{r})$  fallen durch die Normierung mit  $C_{Norm}$  nach Gleichung (39) verhältnismäßig klein aus.

### 4.6.6 Iteration und Konvergenz

Nachdem in den vorangegangenen Abschnitten bereits an zahlreichen Beispielen gezeigt wurde, gegen welche Endwerte das INF konvergiert, sollen nun die einzelnen Iterationsschritte genauer analysiert werden.

Zu diesem Zweck wurde ein einzelnes Neuron im INF ausgewählt, an dessen Position in den Sensordaten ein Spike<sup>31</sup> vorhanden ist.




Abbildung 44: Spike-Attraktordiagramm. Gegenüber den vorangegangenen 3D-Darstellungen sind hier die Dickenwerte auf der horizontalen Achse dargestellt. Auf der vertikalen Achse ist die Wechselwirkungsstärke aufgetragen. Man beachte den Sensorwert ganz rechts am Rand.

In Bild (44) sind die Attraktoren dargestellt, die an der  $(x, y)$ -Position des Spike-Wertes in den Meßdaten auftreten.

<sup>31</sup>An dieser Position tritt ein Spike auf, d. h. ein isolierter, extrem hoher Sensorwert, der synchron auf allen Kanälen erscheint. Vergl. Abschnitt 3.3.4.

Auf der horizontalen Achse sind die "Dickenwerte" aufgetragen; jede dargestellte Linie stellt einen einzelnen Anregungs–Attraktor für das untersuchte Neuron dar.


Auf der vertikalen Achse ist die Stärke der Attraktoren aufgetragen, sowie die Gewichtsfunktionen (Gaußglocken) mit denen die Attraktorstärken in Abhängigkeit von ihrem Abstand zum aktuellen Anregungswert modifiziert werden.

Abbildung (44) enthält folgende Komponenten:


- Die höchste Spitze ist der aktuelle Anregungswert des Neurons, d. h. die aktuell vermutete "Dicke"  $m$  des Öls ( $m \approx 116$ ).
- Die drei etwas kürzeren Linien markieren auf der horizontalen Achse die Meßwerte von drei Sensoren. Der linke Sensorwert votiert für eine Dicke  $m_1$  von rund 105, während der mittlere Sensorwert  $m_2$  bei rund 120 liegt. Der rechte einen Meßwert von  $m_3$  bei etwa 125. Die dargestellten Amplituden von  $m_1$ ,  $m_2$  und  $m$  hängen von der Wahl von  $\eta_A$  ab, sind hier im Attraktordiagramm aber nicht relevant. Die Amplituden wurden nur zur besseren Unterscheidung von den Nachbarschaftsattraktoren in der dargestellten Weise gewählt.
- Im linken Teil der Grafik erkennt man eine Ansammlung von Attraktoren, die durch die Nachbarschaftsinteraktion generiert wurden.
- Die beiden Gaußglocken bezeichnen die Reichweiten der Ausreißer–Elimination. Die punktierte Kurve gehört zum Antennenterm der Regel **I.2**. Die Reichweite der Nachbarschafts–Attraktoren (gestrichelte Kurve) ist erkennbar größer.

Insgesamt ist daher zu erwarten, daß sich der Schätzwert  $m$  im nächsten Iterationsschritt nach links bewegen wird.

Die nebenstehende Abbildung bestätigt diese Erwartung. Man kann deutlich erkennen, daß sich der  $m$ -Wert nun bereits von 116 auf etwa 112 verschoben hat. Darüber hinaus haben sich auch die Attraktoren, die durch die Nachbarschaft generiert wurden, verändert.




Da sich die prinzipielle Neuronen-Situation noch nicht verändert hat, verschiebt sich der Schätzwert für  $m$  in der folgenden Iteration weiterhin nach links.




Die Anregungswerte der Nachbarschaftsneuronen konvergieren etwas schneller gegen einen gemeinsamen Schätzwert, da sie (bezogen auf ihre Nachbarn) bei günstigeren Startwerten beginnen<sup>32</sup>.

Die weiteren Abbildungen geben die nachfolgenden Iterationsschritte wieder. Die nebenstehende Grafik zeigt den Zustand nach 6 Iterationen. Deutlich kann man erkennen, daß der Einfluß des rechten Sensorinputs weiter abnimmt, da er mit der schmalere Gaußglocke gewichtet wird.




<sup>32</sup>Sie sind nicht mit einer Spike-Störung beaufschlagt, sondern enthalten nur den kleineren Rauschanteil.


Bereits eine Iteration später wird der rechte Sensorwert nur noch als Ausreißer bewertet und geht daher nicht mehr so stark in die Schätzung von  $m$  ein. Der Wert von  $m$  verschiebt sich daher schneller nach links auf die Schätzwerte der Nachbarschaftsneuronen hin.



Da auch der linke Sensorwert inzwischen als Ausreißer "erkannt" wurde, verschiebt sich der Wert von  $m$  nun sehr rasch nach links. Das nebenstehende Bild zeigt die Verhältnisse nach insgesamt 8 Iterationen. Die breitere Gaußglocke, mit der die Attraktoren der Nachbarschaftsneuronen gewichtet sind, beeinflusst nun auch die Nachbarneuronen. Man kann dies deutlich an den Verschiebungen der Nachbarschaftsattraktoren erkennen.



Nach 9 Iterationsschritten hat der Schätzwert  $m$  bereits fast seinen endgültigen Wert erreicht. Die Wechselwirkung zwischen dem betrachteten Neuron und seiner Nachbarschaftsumgebung ist nun sehr groß. Man kann bereits erkennen, daß sich die Nachbarschaftsattraktoren jetzt in zwei Gruppen differenzieren, die



symmetrisch um den  $m$ -Wert angeordnet sind. Dies ist das gewünschte Ergebnis, denn das INF befindet sich nun in einem stabilen Zustand. Ein stabiler Punkt ist genau dadurch gekennzeichnet, daß die Attraktoren, die eine

Vergößerung von  $m$  anstreben, genauso stark sind wie jene, die für eine Verringerung votieren.




Abbildung 45: Spike-Attraktoren im Endzustand

Abbildung (45) zeigt schließlich den Zustand, in dem das Neuron mit seinen Nachbarn asymptotisch zur Ruhe kommt. Die Sensorinput-Attraktoren auf der rechten Seite spielen nun keine Rolle mehr, da sie durch die Interaktion mit den Nachbarneuronen als Ausreißer identifiziert und eliminiert wurden.

Der hier gezeigte Fall tritt typischerweise nur bei Spikes auf. Ist nur ein Meßkanal mit einem hohen Fehler beaufschlagt (Ausreißer), dann wird auch nur dessen Attraktor eliminiert. Die übrigen Sensor-Attraktoren liegen dann meist innerhalb oder zumindest in der Nähe der Nachbarschaftsattraktoren.

## 5 Diskussion der Parameter

In der Iterationsregel **I.2** aus Gleichung (36) treten verschiedene Parameter auf, deren Einfluß auf das Ergebnis im folgenden geklärt werden soll.

Die Diskussion der Parameter bildet den Kern der vorliegenden Arbeit. Im folgenden Abschnitt werden sie nun einzeln variiert und ihre Wirkung auf das Verhalten des INFs untersucht. Hierbei entstehen Diagramme, die für jeden Parameter jeweils eine Kurvenschar enthalten.

Im einzelnen werden folgende Einflußgrößen diskutiert:

- Der Zeitskalenfaktor  $\tau$
- Der Reichweitenparameter  $\sigma_N$
- Die relative Gewichtung zwischen Sensor- und Nachbarschaftstermen über  $\eta_A$  und  $\eta_N$
- Die Wahl der Startwerte für die INF-Aktivitätsverteilung
- Die Größenwahl der Nachbarschaft mittels  $r_N$

Da sich die Parameter untereinander z. T. erheblich beeinflussen, kann man nur sehr schwierig allgemeingültige Regeln zu deren Wahl angeben. Die parametrisierten Diagramme sollen jedoch einen Eindruck von verschiedenen Aspekten der Parameterwahl bieten.

Zu diesem Zweck werden die einzelnen Parameter getrennt variiert. Die Messungen von *Konvergenzgrad* und *Konvergenzzeit* liefern dann Kriterien für die Wahl der Parameter.

Es wird sich dabei zeigen, daß einige bisher benutzte Parameter noch nicht optimal gewählt wurden. Sie werden dennoch beibehalten, da die erzielten Ergebnisse sonst nicht mehr miteinander vergleichbar wären.

Daß man überhaupt mit *ad hoc* gewählten Parametern bereits gute Ergebnisse erzielen kann, ist ein besonderer Vorteil und Hinweis auf die Robustheit des hier vorgestellten Verfahrens.

Zur Auswahl der Diagramme sei an dieser Stelle noch angemerkt, daß sich hinter den einzelnen Abbildungen zumeist ein enormer Rechenaufwand verbirgt. Es macht daher auch kaum Sinn, zahlreiche Parameterkombinationen "blind" durchzuprobieren.

Das Verständnis der isolierten Auswirkung jedes Parameters liefert im allgemeinen auch Hinweise auf einen günstigen, wenn nicht sogar fast optimalen, Parametersatz für die jeweilige Anwendung.

## 5.1 Einfluß der Zeitskalierung

In den beiden vorgestellten Iterationsregeln **I.1** und **I.2** (vergl. Gleichung (36)) tritt jeweils ein Faktor  $\tau$  auf, der hier als *Zeitskalenfaktor* bezeichnet wird ([25]). Vereinfacht haben die Iterationsregeln die Form

$$\tau \dot{m} = \eta_A f_A(m, \dots) + \eta_N f_N(m, \dots) \quad (40)$$

$$\dot{m} = \frac{1}{\tau} [\eta_A f_A(m, \dots) + \eta_N f_N(m, \dots)] \quad (41)$$

Die Änderung von  $m$  hängt also von den Funktionen in den eckigen Klammern ab, skaliert mit einem Faktor von  $\frac{1}{\tau}$ .

Große Werte von  $\tau$  verlangsamen die Änderung von  $m$ , während kleine Werte sie beschleunigen.

Der Klammerterm beschreibt über die gebildeten Attraktoren eine Korrektur für  $m$ : der alte Schätzwert von  $m$  wird in Richtung der stärksten Attraktoren verschoben.

Dieses Verhalten legt nahe, daß es eine kritische untere Grenze für  $\tau$  geben muß, bei der die Korrekturen nicht mehr zu einer konvergenten Änderung von  $m$  führen. Vielmehr kann der Wert von  $m$  dann über einen stabilen Fixpunkt hinweg springen ohne in diesen zu relaxieren. Das ganze INF

kann dann im allgemeinen keinen stabilen Zustand mehr einnehmen, d. h. es kommt nicht mehr in einem Attraktor zur Ruhe.

Den kritischen Wert von  $\tau$  kann man direkt aus Gleichung (41) abschätzen: der Wert von  $m$  springt mit diesem  $\tau_{min}$  binnen einer einzigen Iteration direkt auf seinen Endwert  $m_0$ , den er sonst erst nach einer ganzen Reihe von Iterationen erreicht hätte. Verkleinert man  $\tau$  noch weiter, so springt  $m$  jeweils über sein Ziel hinaus und verfehlt dabei den Fixpunkt im Attraktor.

Gleichung (41) enthält aber noch weitere Variablen, von denen die Grenze von  $\tau$  abhängt:

- $\eta_A, \eta_N$ : Diese Variablen haben verglichen mit  $\tau$  einen genau reziproken Einfluß. Sie sollen hier beide  $\leq 1$  angenommen werden. Damit bleibt die Konvergenz von  $m$  wahrscheinlich, wenn

$$\frac{1}{\tau} \cdot \eta_A \leq 1 \quad \text{und} \quad \frac{1}{\tau} \cdot \eta_N \leq 1 \quad \text{gilt.} \quad (42)$$

- $f_A$ : Diese Funktion beschreibt die Änderung von  $m$  aufgrund der Meßwert-Attraktoren. In Regel **I.2**, Gleichung (36), wurde dieser Term als

$$f_A := \sum_{i=1}^3 (m_i(\vec{r}) - m(\vec{r})) \cdot e^{-\frac{(m_i(\vec{r}) - m(\vec{r}))^2}{2\sigma_A^2}} \quad (43)$$

definiert. Die  $e$ -Funktion in Gleichung (43) ist immer  $\leq 1$ , da ihr Exponent immer negativ oder null ist.

Die Funktion  $x \cdot e^{-\frac{x^2}{2\sigma^2}}$  hat ihr Maximum bei  $x = \sigma$  mit dem Wert  $\frac{\sigma}{\sqrt{e}}$ . Der Maximalwert für die Summe (der nie erreicht wird, solange nicht alle Attraktoren am identischen Ort liegen), ist damit

$$\hat{f}_A = 3 \cdot \frac{\sigma_A}{\sqrt{e}} \quad (44)$$

Konvergentes Verhalten des INFs gegen einen stabilen Feldzustand ist daher zumindest zu erwarten, wenn

$$\frac{1}{\tau} \cdot \hat{f}_A \leq 1 \quad (45)$$

- $f_N$ : Diese Funktion beschreibt die Änderung von  $m$  aufgrund der Nachbarschafts-Attraktoren. Auch  $f_N$  liefert eine Bedingung für  $\tau$ , die aber wegen der Nachbarschaftsgewichtung komplizierter ausfällt. Da in dieser Arbeit die experimentelle Parameteruntersuchung im Vordergrund steht, soll auf die analytische Darstellung hier verzichtet werden.

Abbildung (46) bestätigt die Existenz einer unteren Grenze für  $\tau$ . Dargestellt ist der Fehlerkennwert  $\epsilon_{MSE}$  über den Iterationsschritten. Man erkennt, daß der Fehlerkennwert gegen einen Wert bei 30 konvergiert, solange  $\tau$  eine gewisse Grenze (hier etwa 0,8) nicht unterschreitet. Danach kommt es zu anschwellenden Fluktuationen im INF, die sich im Kennwert  $\epsilon_{MSE}$  zeigen.




Abbildung 46: Zum Zeitskalenfaktor  $\tau$

Mit wachsenden  $\tau$ -Werten konvergiert der Fehlerkennwert immer langsamer gegen seinen Endwert — daher die Bezeichnung *Zeitskalenfaktor* für  $\tau$ .

Wie in Gleichung (42) gezeigt wurde, wirken z. B. die Faktoren  $\eta_A$  und  $\eta_N$  genau reziprok zu  $\tau$ . Die Vergrößerung dieser Faktoren wirkt sich daher genauso wie eine Verkleinerung von  $\tau$  aus.

## 5.2 Einfluß der Attraktorreichweiten

Auf Seite 48 wurde der Reichweitenparameter  $\sigma_N$  bereits kurz erwähnt. Die Reichweite der Attraktoren hängt vom Parameter  $\sigma_N$  im Exponentialterm der Nachbarschaftswechselwirkung in Gleichung (36), zweite Summe, ab. In der folgenden Parameterstudie geht es um die Frage, ob und wie stark der Endwert  $m$  jedes einzelnen Neurons vom gewählten  $\sigma_N$  abhängt.

Das nebenstehende Attraktordiagramm zeigt neben den Attraktoren auch deren Gewichtung in Abhängigkeit vom Abstand zum aktuellen  $m$ . Man erkennt, daß die Elimination von Ausreißern direkt von der Größe von  $\sigma_N$  abhängt.




Abbildung 47:  $\sigma_N$  im Attraktorendiagramm (gestrichelte Kurve)

Um dies zu zeigen, wird  $\sigma_N$  in Schritten von 5 variiert. Alle übrigen Parameter der Simulation werden festgehalten. Das Resultat ist in der folgenden Abbildung (48) dargestellt.




Abbildung 48: Einfluß des Nachbarschaftsparameters  $\sigma_N$  auf das Fehlermaß  $\epsilon_{MSE}$

Die parametrisierte Grafik zeigt den Wert des Fehlermaßes  $\epsilon_{MSE}$ , aufgetragen über der Simulationszeit.

Man erkennt, daß offenbar

$$\lim_{t \rightarrow \infty} \epsilon_{MSE}(t) \approx 30 \quad (46)$$

konvergiert.

Entgegen der Erwartung hängt also zumindest das Fehlermaß  $\epsilon_{MSE}$  kaum von  $\sigma_N$  ab. Gleiches gilt im übrigen auch für das Fehlermaß  $\epsilon_V$ , das sich analog zu  $\epsilon_{MSE}$  verhält.

Der Fangbereich, den die Gaußglocke zu  $\sigma_N$  definiert, hat also nur eine geringe Wirkung auf die Fehlermaße. Die Wirkung von  $\sigma_N$  zeigt sich aber, wenn man den Zustand des INFs betrachtet:




Abbildung 49: Wirkung von  $2\sigma_N^2 = 5$ . Links das INF nach 100 Iterationen und auf der rechten Seite das Attraktorbild eines Spikes nach der ersten Iteration. Die gestrichelte Linie markiert den Fangbereich von  $\sigma_N$ .




Abbildung 50: Wirkung von  $2\sigma_N^2 = 10$ . Links das INF nach 100 Iterationen und auf der rechten Seite das Attraktorbild eines Spikes nach der ersten Iteration. Der Fangbereich von  $\sigma_N$  ist hier bereits etwas breiter.




Abbildung 51: Wirkung von  $2\sigma_N^2 = 30$ . Links INF nach 100 Iterationen und auf der rechten Seite das Attraktorbild nach der ersten Iteration.




Abbildung 52: Wirkung von  $2\sigma_N^2 = 40$ . Links INF nach 100 Iterationen und auf der rechten Seite das Attraktorbild nach der zweiten Iteration.




Abbildung 53: Wirkung von  $2\sigma_N^2 = 100$ . Links INF nach 100 Iterationen und auf der rechten Seite das Attraktorbild nach der ersten Iteration.

Im Bereich von  $2\sigma_N^2 = 5 \dots 30$  tritt eine sichtbare Verbesserung in der Störungselimination auf. Man kann dies an der zunehmenden Glättung der Oberfläche erkennen. Spikes können hier aber noch nicht eliminiert werden, da deren Werte so weit von den Attraktoren der Nachbarschaft entfernt sind, daß sie nicht beeinflußt werden (Abbildungen (49) bis (51)).

Dies ändert sich erst bei etwa  $2\sigma_N^2 = 40$ . Auf der rechten Seite von Abbildung (52) kann man erkennen, daß die Nachbarschaftsattraktoren sich nun im Einflußbereich der  $\sigma_N$ -Gaußglocke befinden. Die Wahl des Wertes von  $\sigma_N$  beeinflußt jetzt die Dynamik des Schätzwertes und zieht diesen zu den Nachbarschaftsattraktoren hin. Die Sensorwerte der drei Antennen werden dabei quasi 'überstimmt', d. h. sie werden so gering gewichtet, daß ihr Einfluß deut-

lich abnimmt. Die Spikes können also erst ab dieser Grenze für  $\sigma_N$  vom INF automatisch detektiert und eliminiert werden.

Wenn nun die Resultate immer besser werden, je breiter man die Reichweite der Nachbarschaftsattraktoren festlegt (größeres  $\sigma_N$ ), dann stellt sich die Frage, ob man nicht ganz auf den  $\sigma_N$ -Exponentialterm in der Iterationsregel **I.2** verzichten<sup>33</sup> kann. Dies wäre gleichbedeutend mit einer Wahl von  $\sigma_N \rightarrow \infty$ .

Aus Abbildung (53) erkennt man, was bei zu großer Wahl von  $\sigma_N$  geschieht: zwar konvergiert das INF augenscheinlich sehr gut gegen die ungestörten Eingangsdaten, jedoch zeigt sich nun eine deutliche Veränderung bei den Attraktoren der Nachbarn. Je größer  $\sigma_N$  gewählt wird, desto weniger werden die Neuronen gezwungen, sich ihrer unmittelbaren Nachbarschaft anzupassen.

Wenn diese Zwangsbedingung entfällt, wird die Oberfläche der Verteilungsgrafik wieder rauher. Außerdem liegen dadurch die Attraktoren der Nachbarschaft auch nach vielen Iterationen nicht mehr dicht zusammen, sondern sie verteilen sich über einen Bereich, dessen Breite mit  $\sigma_N$  korreliert ist.

Das Fazit der Untersuchung von  $\sigma_N$  ist daher: man sollte das  $\sigma_N$  so klein wählen, daß die Spikes in den Meßdaten gerade noch zufriedenstellend unterdrückt werden.

---

<sup>33</sup>D. h. alle wechselwirkenden Nachbarn *im Radius*  $r_N$  werden gleich gewichtet (siehe Abbildung (37), Seite 59, Rechteckfunktion).

### 5.3 Gewichtung der Iterationsterme: $\eta_A$ und $\eta_N$

In Gleichung (40) wurde bereits die Iterationsregel **I.2** in einer vereinfachten Form dargestellt:

$$\tau \dot{m} = \eta_A f_A(m, \dots) + \eta_N f_N(m, \dots) . \quad (47)$$

Die Änderung ( $\dot{m}$ ) der Meßwertschätzung in jedem Punkt ergibt sich demzufolge aus einem sensorischen Anteil  $f_A$  und einem interaktiven Anteil  $f_N$ .

Über die Vorfaktoren  $\eta_A$  und  $\eta_N$  kann man den sensorischen Input  $f_A$  gegen die Nachbarschaftsinteraktion  $f_N$  gewichten.

Im nachfolgenden Diagramm wurden die Parameter  $\eta_A$  und  $\eta_N$  jeweils folgendermaßen gewählt<sup>34</sup>:

$$\eta_A := \nu \quad \text{und} \quad \eta_N := 19 - \nu \quad \text{mit} \quad \nu = 1 \dots 19 \quad (48)$$

Wie man in Abbildung (54) erkennen kann, hat die Wahl des Verhältnisses  $\eta_N : \eta_A$  einen deutlichen Einfluß auf die Entwicklung des Fehlermaßes  $\epsilon_{MSE}$  bei jedem Iterationsschritt des INFs.

---

<sup>34</sup>In Abschnitt 5.1 wurde bereits festgestellt, daß der Wertebereich von  $\eta_A$  und  $\eta_N$  durch die Wahl von  $\tau$  eingeschränkt wird. Bei den nachfolgenden Simulationen wurde deshalb der Wert  $\tau$  gegenüber den vorangegangenen Simulationen vergrößert.




Abbildung 54: Das Fehlermaß  $\epsilon_{MSE}$  über der Zeit. Die Kurvenschar ist mit dem Verhältnis  $\eta_N : \eta_A$  parametrisiert.

Bis zu einem gewissen Verhältnis  $\eta_N : \eta_A$  (etwa 17:2) verbessern sich die Resultate des INFs im Sinne des gewählten Fehlermaßes:  $\epsilon_{MSE}$  konvergiert gegen immer geringere Werte. Jenseits dieser Grenze steigt der Fehler jedoch rasch an.

Zwischen den beiden Extremfällen, wenn jeweils eine Komponente (Nachbarschaft oder sensorischer Input) dominiert, existiert also ein optimales Parameterverhältnis bei dem der Fehler  $\epsilon_{MSE}$  minimal wird.

Das nebenstehende Diagramm zeigt den Fehler  $\epsilon_{MSE}$  nach jeweils 100 Iterationen. Die gewählten Verhältnisse  $\eta_N : \eta_A$  entsprechen denjenigen aus Abbildung (54).




Abbildung 55: Fehlermaß  $\epsilon_{MSE}$  aus Abbildung (54) nach je 100 Iterationen

Wie zu erwarten war, erhält man nur für ein gewisses Verhältnis von  $\eta_N$  zu  $\eta_A$  (hier<sup>35</sup> etwa 9:1) ein optimales Ergebnis. Der Grund liegt darin, daß es *nicht optimal sein kann*, wenn man *nur* die Sensordaten ( $\eta_A \gg \eta_N$ ) oder *nur* die Nachbarschaftsdaten ( $\eta_A \ll \eta_N$ ) berücksichtigt.

Man muß an dieser Stelle aber anmerken, daß das Optimalverhältnis unter Umständen auch sehr erheblich von den gewählten Startwerten abhängt. In den Diagrammen (54) und (55) wurden die Sensormittelwerte als Startwerte gewählt. Vor dort aus beginnend ist die Wahl eines hohen  $\eta_N$  sicherlich sinnvoll.

Es erscheint zweckmäßig, immer das Optimum des geringsten Fehlers<sup>36</sup> anzustreben.

Leider zeigt sich bereits in der Simulation, daß ein scheinbar geringer  $\epsilon_{MSE}$ -Fehler mit einer deutlichen Deformation der Werteverteilung im INF einhergehen kann. Es tritt hier ein offensichtlicher Nachteil der verwendeten Ähnlichkeitsmetrik  $\epsilon_{MSE}$  zu Tage: obwohl der Fehler  $\epsilon_{MSE}$  klein ist, konvergiert die Verteilung im INF trotzdem nicht gegen die reale Verteilung.

Die beiden Bilder (56) und (57) zeigen zwei mögliche Extremfälle, wie sie in

<sup>35</sup>In Abbildung (54) etwa 17:2, also rund 9:1.

<sup>36</sup>Fehler im Sinne des gewählten Fehlermaßes.  $\epsilon_{MSE}$  und  $\epsilon_V$  liefern ähnliche Resultate, so daß auf die Diskussion von  $\epsilon_V$  hier verzichtet wird.

Diagramm (55) an den Rändern auftreten:

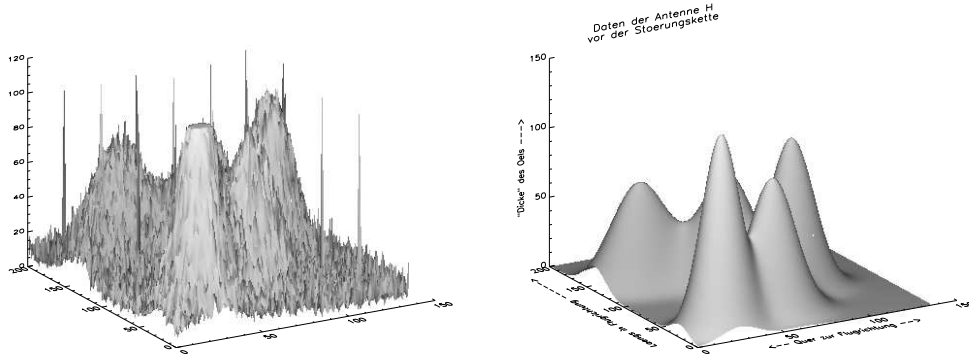


Abbildung 56: Links:  $\eta_A \gg \eta_N$  nach 100 Iterationen, rechts: Synthetische Originaldaten ohne Störungen zum Vergleich

In Abbildung (56, links) dominiert der sensorische Input. Die Nachbarschaftswechselwirkung wird kaum berücksichtigt und reduziert allenfalls geringfügig das Rauschen.

In Abbildung (57) dominiert die Interaktion mit der Nachbarschaft. Die Zustandsfläche des INFs erscheint dadurch zwar sehr glatt, jedoch treten zwischen den einzelnen Signalmaxima deutliche Verbindungen auf, die eigentlich gar nicht vorhanden sein sollten.




Abbildung 57:  $\eta_A \ll \eta_N$  : Links das INF nach 100 Iterationen und rechts die Fehlerentwicklung (Obere Kurve:  $\epsilon_V$ , untere Kurve:  $\epsilon_{MSE}$ )

Berücksichtigt man die Deformationserscheinungen an den Zustandsflächen, so erscheint die Wahl  $\eta_A \approx \eta_N$  hier günstiger als das Verhältnis von 9:1 von Seite 84.

Entsprechende Simulationen bestätigen diese Erwartung. Allerdings ist die Beurteilung, wie starke Deformationserscheinungen noch im Toleranzbereich liegen, sehr subjektiv und hängt zudem vom jeweiligen Anwendungsfall ab. Ausgehend von etwa 1:1 kann man je nach Rauschgehalt des Inputs das Verhältnis in einem kleinen Bereich variieren. Dominiert hingegen  $\eta_A$  oder  $\eta_N$  deutlich, so verliert das INF einige seiner besonderen Eigenschaften: entweder wird die Toleranz gegenüber Rauscheinflüssen verringert, oder die Zustandsfläche konvergiert nicht mehr gegen die reale Verteilung der Sensordaten.

#### 5.4 Einfluß der Startwerte

Die Iterationen nach den Regeln **I.1** und **I.2** des INFs können im Prinzip mit beliebigen Startwerten beginnen<sup>37</sup>.

Die bisher zur Initialisierung benutzten Werte waren die arithmetischen Mittelwerte der Sensorinputs. Diese Wahl war bequem und führt im allgemeinen zu brauchbaren Resultaten: die Aktivitätsverteilung im INF konvergiert dann gegen eine Verteilung, die den realen physikalischen Gegebenheiten entspricht. Dennoch ist die Verwendung eines einfachen Mittelwertes nur suboptimal, denn:

- an Meßpositionen, wo Spikes vorhanden sind, ist der Mittelwert der Sensordaten genau so falsch wie dessen Einzelkomponenten.
- obwohl bekannt ist, daß am Rand des Meßfeldes eine Dicke von 0 vorliegen muß, liefern die Sensoren auch hier ein Rauschsignal.

---

<sup>37</sup>Wenn die Startwerte außerhalb aller Attraktorbereiche liegen, wird das Feld allerdings quasistabil und die Feldverteilung ändert sich überhaupt nicht mehr.

- obwohl ebenfalls bekannt ist, daß die Oberfläche "glatt" sein muß, gilt dies bereits nicht mehr für die als Startwerte gewählten Mittelwerte (bzgl. der Oberflächeneigenschaften siehe auch Seite 42).

Zu Demonstrationszwecken soll nun die Parameterschar aus Abbildung (54) erneut bestimmt werden, diesmal jedoch mit anderen Startwerten. Alle Punkte des INFs werden diesmal mit dem Wert

$$\hat{m} := 0,75 \cdot \max_{\forall \vec{x}} \left( \frac{1}{3} \sum_{i=1}^3 m_i(\vec{x}) \right) \quad (49)$$

initialisiert, d. h. mit 75 % des größten Wertes, den man mit einer einfachen Mittelwertbildung erhält. Diese Wahl (hier  $\approx 116,2$ ) ist für das INF sehr ungünstig: zum einen sind die meisten gewünschten Endwerte deutlich kleiner (vergl. Abbildung (52), Seite 80), zum anderen gibt es gleich am Anfang sehr starke Nachbarschaftsattraktoren.

Die Attraktoren der Nachbarneuronen votieren alle gemeinsam für einen falschen Wert und verstärken sich dabei gegenseitig. Es ist daher für die INF-Dynamik verhältnismäßig schwierig, die Schätzwerte  $m(\vec{x})$  zu verschieben und schließlich einen Endzustand mit geringem Fehler  $\epsilon_{MSE}$  einzunehmen.

Die folgenden Bilder stellen den Zustand des INFs nach 100 Iterationsschritten dar. Variiert wird dabei das Verhältnis von  $\eta_N$  zu  $\eta_A$ ; während also  $\eta_N$  schrittweise vergrößert wird, wird gleichzeitig  $\eta_A$  entsprechend Gleichung (48) reduziert.




Abbildung 58: INF nach je 100 Iterationen bei 'kleinem'  $\eta_N$ .

Links  $\eta_N : \eta_A = 1 : 18$ , rechts  $12 : 7$ .

Bei geringem Einfluß der Nachbarneuronen ( $\eta_N$  klein) schaden die deutlich zu hohen Startwerte für die  $m(\vec{r})$  kaum. Allerdings findet auch nicht die vom INF gewünschte Glättung der Rauschteile statt.




Abbildung 59: INF nach je 100 Iterationen. Links  $\eta_N : \eta_A = 14 : 5$ , rechts  $16 : 3$ .

Je größer der Einfluß der Nachbarn wird, desto stärker behindern die ungünstigen Startwerte den beabsichtigten Konvergenzprozeß im INF.




Abbildung 60: INF nach je 100 Iterationen. Links  $\eta_N : \eta_A = 18 : 1$ , rechts  $19 : 0$ .

Das letzte Bild (Abbildung (60), rechts) ist nur von prinzipiellem Nutzen, da bei  $\eta_N = 19$  gleichzeitig  $\eta_A = 0$  ist. Damit hat der Sensorinput der Antennen *gar keinen* Einfluß mehr auf das Ergebnis und die Nachbarschafts-Interaktion arbeitet nur auf den (falschen) Initialisierungsdaten.

Der Nutzen der Grafik liegt darin, daß man die Wirkung der Nachbarschafts-Wechselwirkung in den Randzonen des Datenfeldes erstmals genauer verifizieren kann: Randneuronen "sehen" auch eine vollständige Nachbarschafts-Umgebung; die Erregung aller Neuronen außerhalb des eigentlichen Datenfeldes wird jedoch als Null angenommen<sup>38</sup>.

Das INF sollte daher folgendes Verhalten zeigen:

1. In der Mitte des INFs sollten die Erregungswerte für eine lange Zeit (d. h. für sehr viele Iterationsschritte) konstant bleiben.
2. An allen 4 Rändern sollten die Werte pro Iterationsschritt absinken, da jedes Randneuron von einer Hälfte seiner Nachbarschaft nur Nullwerte empfängt (diese Hälfte liegt außerhalb des Datenfeldes). Die anderen 50 % der Nachbarn votieren für relativ große Werte, die anfangs dem Initialisierungswert entsprechen.

---

<sup>38</sup>Diese Annahme ist insofern gerechtfertigt, als daß in der vorliegenden Arbeit immer von örtlich begrenzten Ölflecken ausgegangen wird, die sich etwa mittig im abgetasteten Datenfeld befinden.

3. Die Erregung der Neuronen in den Ecken des Datenfeldes sinkt deutlich schneller als an den Kanten, da ein Eckneuron von  $\frac{3}{4}$  seiner Nachbarn Nullwerte als Attraktoren erhält und nur 25 % (maximal) für Werte größer als Null votieren.

Das hier benutzte INF zeigt genau dieses Verhalten.

Die Problematik der zu wählenden Startwerte zeigt sich auch im Fehlerdiagramm für  $\epsilon_{MSE}$ . Das folgende Diagramm verdeutlicht den Einfluß von  $\eta_N : \eta_A$  wie in Diagramm (54) — diesmal jedoch mit den veränderten Startwerten.




Abbildung 61: INF nach je 100 Iterationen. Dargestellt ist analog zu Diagramm (54) das Fehlermaß  $\epsilon_{MSE}$  bei verschiedenen Verhältnissen  $\eta_N : \eta_A$ .

Offenbar hat die Wahl der Startwerte einen gravierenden Einfluß auf den asymptotischen Zustand des INFs.

Zunächst sind die auftretenden Fehlerkennwerte im Vergleich zu Abbildung (54) um rund 1,5 Größenordnungen erhöht. Weiterhin fallen die Resultate hier umso besser aus, je kleiner der Einfluß der Nachbarn gewählt wird. Dieses Verhalten steht nicht im Widerspruch zu Abbildung (54); es wird vielmehr direkt von den ungünstigen Startwerten bestimmt.

Die Startwerte des INFs sollten deshalb mit entsprechender Sorgfalt gewählt werden. Hierbei ist das Vorwissen von entscheidender Bedeutung: wenn man dem Feld günstige Startwerte gibt, dann konvergiert das INF schneller und nimmt im allgemeinen auch asymptotisch einen korrekten Endzustand ein, d. h. das INF befindet sich dann in einem Fixpunkt, der der realen Verteilung der Meßgrößen entspricht.

Bei den Messungen in dieser Arbeit ergibt sich eine in diesem Sinne günstige Startwertverteilung beispielsweise durch die Bedingungen

1. An den Rändern des Meßbereichs befindet sich kein Öl (die Dicke ist exakt null).
2. Über die gesamte Fläche gesehen befindet sich das Öl (die *Region-of-interest*) ungefähr in der Mitte.

Eine Startwertverteilung, die einer in der Mitte zentrierten Gauß- oder Cosinus-Glockenkurve entspricht, erfüllt diese Kriterien.

In den hier durchgeführten Simulationen wurde als Startwert für jeden Punkt der Mittelwert der Sensordaten am jeweiligen Ort gewählt. Dieser Wahl liegt die Annahme zugrunde, daß dieser Mittelwert in der überwiegenden Mehrzahl der hier zu erwartenden Meßwerte eine gute Approximation des tatsächlichen Wertes der gemessenen Größe ist.

Auch eine Kombination dieser beiden Verfahren kann günstige Startwerte liefern. Eine Mittelung mit einer Glockenfunktion als Gewichtsfunktion erfüllt die beiden oben geforderten Bedingungen (1.) und (2.).

Die Wahl günstiger Startwerte beschleunigt allgemein die Konvergenz der INF-Verteilung in den jeweils nächstliegenden Attraktor. Bei ungünstigen Startwerten konvergiert das INF gelegentlich in einen Fixpunkt, der zwar ebenfalls stabil ist, dessen Feldzustand jedoch nicht der physikalischen Meßgrößenverteilung entspricht.

Nur wenn die Startwerte gezielt gewählt werden, etwa weil man Vorwissen über die Meßdaten ausnutzen kann, ist die Wahl einer sehr starken Nachbarschaftswechselwirkung günstig.

### 5.5 Einfluß des Nachbarschafts-Radius

Der Radius  $r_N$  hat ebenso einen großen Einfluß auf das INF, wie die gewählten  $\sigma_N$ -Werte.




Abbildung 62: Das Fehlermaß  $\epsilon_{MSE}$  über der Zeit. Die Kurvenschar ist mit dem Nachbarschafts-Radius  $r_N$  parametrisiert. Links für kleine Radien 0...7, rechts für Radien im Bereich 7...16

Da man zwischen den einzelnen Kurven im unteren Abschnitt des rechten Diagramms nur sehr schlecht differenzieren kann, ist dieser Ausschnitt links nochmal vergrößert abgebildet.

Wie man dort erkennen kann, existiert ein Fehlerminimum bei  $r_N \approx 3$ .

Abbildung (63) zeigt schließlich, daß der Fehler tatsächlich bis  $r_N = 3$  abnimmt, danach ein globales Minimum durchläuft und schließlich ab  $r_N = 8$  fast linear ansteigt.




Abbildung 63: Entwicklung des Fehlermaßes  $\epsilon_{MSE}$  bei steigenden Nachbarschafts-Radien  $r_N$ .  
Man erkennt ein Minimum im Bereich  $r_N = 2 \dots 3$ .

Es entstehen so drei Zonen, in denen das Verhalten des Fehlermaßes direkt erklärbar ist:

1. Im Anfangsbereich  $r_N = [0 ; 1]$  ist die Wirkung der Nachbarschaft praktisch noch sehr gering. Wie spätere Bilder zeigen werden, wird hier lediglich das Rauschen etwas reduziert.
2. Im Optimalbereich  $r_N = [1 ; 5]$  gleicht die Nachbarschaft das Rauschen lokal sehr gut aus und reduziert auch hohe Spikes (vergl. Abbil-

dung (64)), solange diese lokal getrennt sind<sup>39</sup>. Immerhin werden hier bei  $r_N = 5$  insgesamt 80 Nachbarneuronen mit in die Bewertung einbezogen.

3. Im linearen Bereich  $r_N > 5$  dominiert die Interaktion mit den Nachbarn klar über den sensorischen Input: hier werden so viele Nachbarn berücksichtigt, daß die ganze Zustandsfläche geglättet wird (vergl. Abbildung (65)).

Die nebenstehende Tabelle gibt einen Überblick über die Zahl der relevanten Nachbarn bei gegebenem Radius  $r_N$ . Die Anzahl der berücksichtigten Neuronen wächst quadratisch mit  $r_N$ , da  $r_N$  eine Kreisfläche definiert. Ab etwa  $r_N = 10$  kann man in der hier vorgesehenen Anwendung des INFs nicht mehr von einer *lokalen* Wechselwirkung zwischen den Neuronen sprechen.

$r_N$	Nachbarn	$r_N$	Nachbarn
0	0	11	376
1	4	12	440
2	12	13	528
3	28	14	612
4	48	15	708
5	80	16	796
6	112	17	900
7	148	18	1008
8	196	19	1128
9	252	20	1256
10	316		

Tabelle 5: Anzahl der Nachbarn bei verschiedenen Radien

Es ist daher anzunehmen, daß die Hinzuziehung von vielen Nachbarn zu einer erkennbaren Deformation der INF-Zustandsflächen führen muß. Die folgenden Abbildungen zeigen hierzu einige Beispiele.

<sup>39</sup>Für Spikes gilt nach Abschnitt 3.3.4, daß es sich um isolierte Meßpunkte handelt; hier ist jedoch gemeint, daß die Spikes nicht in sehr kleinen Abständen auftreten dürfen (sog. Bursts).




Abbildung 64: INF nach je 100 Iterationen. Links  $r_N = 1$ , rechts  $r_N = 3$ .




Abbildung 65: INF nach je 100 Iterationen. Links  $r_N = 10$ , rechts  $r_N = 16$ .

Man beachte die geänderte Skalierung der vertikalen Achse.

In Abbildung (64) erkennt man die Verbesserung durch die Einbeziehung der Nachbarschaft: die Oberfläche wird glatter, ohne daß Position oder Form der Gipfel merkbar modifiziert werden. Gleichzeitig verschwinden die Spikes. Das Verhalten war entsprechend Abbildungen (62) und (63) zu erwarten.

Des weiteren kann man erkennen, daß sich für größere  $r_N$  die Formation insgesamt verändert. Die einzelnen Maxima fließen zusammen und verbreitern sich dabei. Dies entspricht einer globalen Glättung über das gesamte INF. Bei Abbildung (65) ist dabei noch zu beachten, daß entsprechend Diagramm (62) das INF noch nicht vollständig konvergiert ist. Die Veränderung der Form setzt sich deshalb noch weiter fort, ehe das INF schließlich asymptotisch seinen Endzustand in einem Fixpunkt der Felddynamik annimmt.

Auch der Verlauf der beiden Fehlerkennwerte  $\epsilon_{MSE}$  und  $\epsilon_V$  weist einige charakteristische Merkmale auf. Bei kleinen Radien  $r_N$  verlaufen  $\epsilon_{MSE}$  und  $\epsilon_V$  analog korreliert zueinander (Abbildung (66), links). Bei den größeren Radien aus Abbildung (65) ändert sich dieses Verhalten jedoch:




Abbildung 66: Iterationsfehler  $\epsilon_{MSE}$  (untere Kurve) und  $\epsilon_V$  (obere Kurve) über der Zeit. Links  $r_N = 5$ , mittig  $r_N = 10$ , rechts  $r_N = 16$ .

Anhand der beiden rechten Kurvenverläufe erkennt man, daß die Dynamik im INF auch nach 100 Iterationen noch stark aktiv ist, da die Steigungen der Kurven noch deutlich verschieden von Null sind.

Weiterhin kann man feststellen, daß auch eine starke Vergrößerung von  $r_N$  immer zu einer asymptotisch stabilen Fehlerkonvergenz führt.

Ob die Dynamik im INF bereits abgeklungen ist, kann man übrigens auch an der Attraktordarstellung erkennen, die in dieser Arbeit verwendet wird:




Abbildung 67: Attraktorbilder zu  $r_N = 5$  (Links),  $r_N = 10$  (Mitte),  $r_N = 16$  (Rechts). Abszissen: Dickenwerte, Ordinaten: Attraktorstärken; vergl. Abbildung (44).

Entsprechend ihren  $r_N$  treten in den Attraktordiagrammen von links nach rechts immer mehr Attraktoren auf.

Im linken Bild befindet sich der Schätzwert  $m$  ungefähr zentriert zwischen den Attraktoren der gewichteten Nachbarschaftsneuronen. Der Wert von  $m$  verändert sich in den nachfolgenden Iterationsschritten kaum noch und kommt so (asymptotisch) zur Ruhe.

In beiden rechten Bildern sind die Nachbarschaftsattraktoren noch nicht symmetrisch um den aktuellen Wert von  $m$  angeordnet. Dies bedeutet, daß sich die Position von  $m$  auf der Abszisse wahrscheinlich noch deutlich verschieben wird.

Beim Vorhandensein vieler Nachbarschaftsattraktoren (etwa in Abbildung (67), rechts) kann man nach einigen Iterationsschritten deutlich die Form der Nachbarschaftsgewichtung  $g_{cos}(\vec{r}_k)$  erkennen: im vorliegenden Fall die Cosinusglocke aus Abschnitt 4.6.5.

Aus den vorliegenden Ergebnissen lassen sich keine allgemeinen formalen Kriterien ableiten, die automatisch in jedem Fall zu einer günstigen Wahl des  $r_N$  führen. Anhaltspunkte zur Bestimmung ergeben sich jedoch aus der Stärke der zu kompensierenden Störungen. Ein anderer wichtiger Punkt sind die physikalischen Gesetzmäßigkeiten in den Meßgrößen; der Radius  $r_N$  kann die maximal auftretenden Steigungen (Gradientenwerte) in den stabilen Feldverteilungen begrenzen.

## 6 Untersuchung realer Meßdaten

In den vorangegangenen Abschnitten wurde ein Verfahren beschrieben, mit dem Sensorfusionsprobleme allgemein gelöst werden können. Die dargestellte Methodik soll nun auf reale Meßdaten angewendet werden.




Abbildung 68: Geplante Meßdatenverarbeitung

Zur Gewinnung der realen Daten wurde im Rahmen einer normalen Ölbekämpfungsübung eine bekannte Ölmenge auf der Wasseroberfläche verteilt. Anschließend wurde das Testgebiet mit einem Meßflugzeug überflogen. Am Flugzeug waren die Antennen angebracht, deren aufgezeichnete Meßdaten im folgenden ausgewertet werden. Die auf diese Weise durchgeführte Radiometermessung liefert Meßwerte für die Strahlungstemperatur in drei Frequenzbereichen.

Ein physikalisches Modell zur Umwandlung eines Temperaturmeßwertes in einen Schichtdickenwert steht zur Zeit noch nicht zur Verfügung. In dieser Arbeit werden die Temperaturwerte daher direkt als Eingangsdaten für das INF verwendet.

Bei der Messung sind einige Besonderheiten der Meßapparatur zu beachten, die die Meßwerte ungünstig beeinflussen können. Die entsprechenden Einflußfaktoren werden im folgenden beschrieben und innerhalb einer Vorverarbeitungsstufe kompensiert.

## 6.1 Rauschsignale

Bei passiven Radiometermessungen erhält man Rauschsignale. Das Nutzsignal gewinnt man in der Regel dadurch, daß das Signal verstärkt und gleichgerichtet wird.

Das auf diese Weise erhaltene Signal ist jedoch immer noch ein Rauschsignal. Zu Gewinnung eines Temperaturwertes wird das Signal daher in klassischen Verfahren mit einem Tiefpaßfilter geglättet.

In Abschnitt 4 wurde festgestellt, daß sich das Rauschen der einzelnen Eingangssignale nicht wesentlich auf den Output eines INFs auswirkt. Es macht daher im Hinblick auf die Verarbeitung im Neuronalen Feld keinen Sinn, dem INF einen Tiefpaßfilter vorzuschalten.

Die Signale der Antennen können daher direkt in das INF eingekoppelt werden. Dies ist ein Vorteil des vorgestellten Verfahrens, da das INF auch die Funktionalität eines Tiefpasses enthält.

Vor der eigentlichen Untersuchung der realen Meßwerte soll nun zunächst die Meßapparatur eingehend vorgestellt werden.

## 6.2 Gewinnung der Daten, Meßaufbau




Abbildung 69: Meßprinzip (aus [24])

Abbildung (69) zeigt den prinzipiellen Ablauf der Messung: ein Flugzeug überfliegt in einer Höhe von rund 300 m (1000 ft) das Meßgebiet, in dem sich ein Ölfleck auf dem Wasser befindet. Am Flugzeug befinden sich schwenkbare Antennen, die die Meeresoberfläche zeilenweise äquidistant abtasten. Der gesamte Abtastwinkel beträgt hierbei  $\Theta_S = 76^\circ$ .

Die auf diese Weise erzielbare räumliche Dichte der Meßpunkte auf der Wasseroberfläche hängt somit von der Flughöhe, der Fluggeschwindigkeit und der lateralen Abtastgeschwindigkeit quer zur Flugrichtung ab. Die gewählte Flughöhe von 300 m ist ein Kompromiß zwischen der Dichte der Meßpunkte und der Breite des insgesamt abgetasteten Meßstreifens.

### 6.2.1 Ortstreue der Meßwerte

Bei dem Entwurf eines INFs zur Bearbeitung der Meßwerte ist es sehr wichtig, die exakten Meßpunktpositionen zu kennen.

Hierbei interessiert zum einen die absolute Lage jedes Meßpunktes im Meßfeld, zum anderen aber auch die relative Lage der Punkte zueinander. Die relative Position muß ggf. in den Nachbarschaftswchselwirkungen berücksichtigt werden.

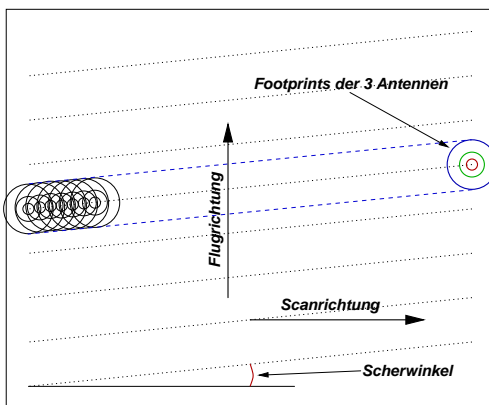


Abbildung 70: Scherungseffekt infolge der Eigenbewegung des Flugzeugs

Die absoluten Positionen bestimmen die Abbildung der Meßorte auf die Neuronenpositionen im INF. Wie man im nebenstehenden Bild (70) erkennen kann, führt die Eigenbewegung des Flugzeuges während der Messung zu einer Scherung des Abtastrasters auf der Wasseroberfläche.

Der auftretende Scherwinkel nimmt mit steigender Fluggeschwindigkeit zu und mit steigender horizontaler

Scanfrequenz ab. Die Fluggeschwindigkeit ist physikalisch durch die minimale Fluggeschwindigkeit des Flugzeugs begrenzt<sup>40</sup>.

Die maximale Scanfrequenz wird durch die Mechanik der Meßapparatur begrenzt, die in der folgenden Abbildung (71) skizziert ist.

Gegenüber dem prinzipiellen Aufbau (Abbildung (71), links) weist die Realisierung (Abbildung (71), rechts) einen wesentlichen Unterschied auf: Die Umlenkung der Antennen erfolgt nicht durch einen hin- und herschwingenden Spiegel, sondern durch eine schnell rotierende Trommel (Umlauffrequenz

<sup>40</sup>Die hier benutzten Daten wurden von einer Do 228 LM Propellermaschine aufgenommen.

10 Hz), in der ein beidseitiger Spiegel<sup>41</sup> fest montiert ist (= 20 Hz Abtastfrequenz).

Die Trommellösung hat zwar den Nachteil, daß die wirkliche Meßzeit einer Meßgruppe pro Trommelumdrehung nur  $\frac{76^\circ}{360^\circ} \approx \frac{1}{5}$  der gesamten Umlaufzeit beträgt, jedoch kann man diesen Nachteil durch den Einsatz der zweiten Sensorgruppe teilweise kompensieren. Die zweite Sensorgruppe blickt auf die Rückseite des Umlenkspiegels und mißt somit genau zeitversetzt: während also jeweils eine Antennengruppe Meßwerte von der Meeresoberfläche aufnimmt, kann die andere Gruppe mittels der heißen und kalten Referenzstrahlungsquellen rekali­briert werden.




Abbildung 71: Aufbau der Meßapparatur. Links das Prinzip ([24]), rechts die Realisierung mit zwei Antennengruppen. Der bewegte Reflektor befindet sich innerhalb des rotierenden Zylinders.

Die Anordnung hat den Vorteil, daß bei konstanter Winkelgeschwindigkeit des Spiegels (und gleichmäßiger Flugzeugbewegung) alle Abtastwerte wirklich auf parallelen Geraden eines Meßrasters auf der Wasseroberfläche lie-

<sup>41</sup>Faktisch zwei einzelne Parabolspiegel, die um eine gemeinsame Achse rotieren [38].

gen (vergl. Abbildung (70)). Eine sinusförmige Schwenkbewegung (Abbildung (71), links) wird damit vermieden.

Das rechte Bild zeigt außerdem noch je eine sogenannte *heiße* und *kalte Strahlungsquelle*. Bei Umlauf des Zylinders erlauben diese Referenzquellen die fortlaufende automatische Kalibrierung des Meßsystems.

Ungünstigerweise macht sich die Rekalibrierung evtl. durch eine Offsetverschiebung in den Meßdaten bemerkbar, deren Detektion verhältnismäßig problematisch ist, da es sich typischerweise nur um sehr kleine Korrekturen handelt. Erschwerend kommt noch hinzu, daß die automatische Rekalibrierung nur etwa alle 64 Zeilen stattfindet<sup>42</sup>.

In den digitalen Meßdaten macht sich die Messung mit zwei Sensorgruppen im wesentlichen dadurch bemerkbar, daß in den Meßzeilen mit geraden und ungeraden Nummern unterschiedliche Offsets auftreten. Dies muß bei der Offsetkorrektur vor Einspeisung in das INF berücksichtigt werden.

Die tatsächliche Lage der Meßpunkte wird noch durch eine Reihe weiterer Einflußgrößen bestimmt. Deren qualitative Untersuchung (und ggf. Kompensation) geht jedoch erheblich über den Rahmen dieser Arbeit hinaus. Die wichtigsten Punkte sollen daher hier nur kurz aufgelistet werden:

1. Die Flugparameter müssen kontinuierlich erfaßt werden, z. B. Flughöhe und Geschwindigkeit, Pitch (Neigung des Flugzeugs nach vorn), Roll (Drehung des Flugzeugs um seine Längsachse), Yaw (Nutation der Flugzeugachse um den Flugrichtungsvektor), Crab (Drehung des Flugzeugs um die Hochachse), usw.
2. Nur eine Antenne jeder Gruppe befindet sich in der optischen Achse des

---

<sup>42</sup>Die Rekalibrierung wird mit Hilfe eines nach oben blickenden Himmelsradiometers durchgeführt, dessen Meßintervalle zeitlich etwa 64 Scanlines entsprechen. Die Berücksichtigung der Zenitstrahlung ist erforderlich, da Spiegelbilder der Wolken sonst dünne Ölschichten vortäuschen könnten ([37]).

Systems (H-Kanal). Dadurch bilden die Footprints auf der Wasseroberfläche keine konzentrischen Kreise mehr, sondern sie liegen – abhängig vom Scanwinkel – z. T. deutlich nebeneinander.

Die ungenauen oder fehlenden Messungen einiger Parameter begrenzen die Genauigkeit bei der weiteren Verarbeitung der Meßwerte.

### 6.2.2 Spezielle Probleme der vorliegenden Meßdaten

Für die beschriebene Meßapparatur liegen bisher noch keine Kalibriermessungen aus der Luft vor. Daher ist z. Zt. nicht bekannt, welchen Meßwert man bei einer definierten Ölschichtdicke erhält. Eine solche Messung wäre eigentlich recht unkompliziert durchzuführen, da man lediglich Öl in einen schwimmenden Rahmen gießen müßte. Bei bekannter Ölmenge, bekannter Fläche und ruhiger See könnte man den Kalibrierfaktor bestimmen.

Ohne diese Messung tritt beim Rückschluß von den Meßwerten auf die Öldicke stets ein Kalibrierfaktor auf, dessen Größe unbekannt ist. Man kann diesen Faktor auch nicht aus dem Gesamtvolumen des ausgebrachten Öls bestimmen, da sich in den Randzonen eines Ölflecks Emulsionen und meerwasserüberspülte Zonen bilden. Die hierbei auftretenden Effekte auf die Meßwerte sind bisher noch nicht hinreichend untersucht.

### 6.2.3 Modellwahl

Ein weitaus größeres Problem stellt aber das physikalische Meßmodell dar. In der Projektplanung wurde von einem Modell ausgegangen, das im Kern meßbare Interferenzerscheinungen an der Wasser-Öl-Luft-Grenzschicht postuliert. Die einfallende atmosphärische Mikrowellenstrahlung wird an die-

ser Grenzschicht reflektiert und anschließend vom Flugzeug aus gemessen<sup>43</sup>. Der reflektierten Strahlung ist zudem die temperaturabhängige Eigenemission von Öl und Wasser überlagert.

Bei den verwendeten Meßfrequenzen mit Wellenlängen von rund 3 mm, 8 mm und 16 mm sollten dabei Mehrdeutigkeiten in den Dickenwerten auftreten, die jedoch bisher nicht eindeutig nachweisbar sind.

Es erscheint daher zumindest fraglich, ob das verwendete Modell in seiner derzeitigen Form aufrechterhalten werden kann.

Um nun dennoch die Daten mit dem INF sinnvoll verarbeiten zu können, kann man anstelle der *Dicken* einstweilen mit *Temperaturen* arbeiten. Die Temperaturwerte sind von dem genannten Meßmodell unabhängig und zudem genauso verteilt wie der Ölfilm.

Diagramm (72) zeigt, daß auch aus den Temperaturen bereits Rückschlüsse auf die Öldicke gezogen werden können. Im Diagramm sind die Strahlungstemperaturen über dem Betrachtungswinkel bei verschiedenen Öldicken dargestellt. Die Prozentangaben beziehen sich auf die Abdeckung der Meeresoberfläche mit Öl, da bei sehr dünnen Schichten keine einfach zusammenhängenden Ölschichten mehr entstehen. Die obere




Abbildung 72: Strahlungstemperaturen über dem Einfallswinkel, für verschiedene Öldicken (nach [31])

keine einfach zusammenhängenden Ölschichten mehr entstehen. Die obere

<sup>43</sup>Zur Unterscheidung von Reflektion und Emission der Wasseroberfläche kann man das senkrecht himmelwärts ausgerichtete Zenitradiometer nutzen. Es mißt die Stärke der vom Himmel einfallenden Strahlung (3 K Hintergrundstrahlung, etwa 50 K atmosphärische Strahlung, vergl. [30]) im 89 GHz-Bereich, die von der Witterung (Wolken/Wasserdampf/Regen) beeinflusst wird.

Kurve gehört jeweils zu  $\lambda = 3 \text{ mm}$ , die untere zu  $\lambda = 3 \text{ cm}$ .

In Diagramm (72) erkennt man deutlich eine Abhängigkeit der Strahlungstemperatur von der Ölschichtdicke.

Mit Hilfe eines – evtl. erweiterten – Modells kann man später die Temperaturverteilung wieder als reale Dickenverteilung interpretieren, sobald ein plausibles physikalisches Meßmodell vorliegt.

### 6.3 Vorverarbeitung

Abbildung (73) auf der nächsten Seite soll einen Eindruck von den realen Meßdaten geben.

Im hinteren Bereich des Datenplots erkennt man deutlich eine Erhebung infolge des Öls. Im vorderen Bereich befindet sich das Schiff, das das Öl ausgebracht hat. Schließlich sind ganz vorn noch zahlreiche Spikes erkennbar, die durch Störungen während der Messung entstanden sind.

Wie man an der vertikalen Lage der Meßwerte in Abbildung (73) erkennen kann, sind die Meßwerte mit Offsets behaftet. Auf Seite 53 wurde im Rahmen des INFs ohne Nachbarschaftswirkung darauf hingewiesen, daß bereits das einfache INF – in gewissen Grenzen – Offsets korrigieren kann. Diese einfache Offsetkorrektur durch Mehrheitsentscheidungen zwischen den Sensoren ist hier jedoch nicht mehr ausreichend. Im folgenden Text wird daher eine Offsetkorrektur beschrieben, die das Vorwissen über den hier vorgenommenen Meßvorgang selbst ausnutzt.

Weiterhin erscheint die gesamte Meßdatenverteilung gewölbt. Es handelt sich dabei um einen verfahrensbedingten, systematischen Meßfehler, der im folgenden ebenfalls eliminiert werden muß.




Abbildung 73: Reale Meßdaten, H-Kanal (89 GHz), 600 Scanlines. Im hinteren Bereich die ölverschmutzte Zone, vorn in der Mitte das Signal eines Schiffes.

Der Ölfleck befindet sich im hinteren Bereich von Abbildung (73) (etwa Scanlines 400 bis 600). Bereits das nachfolgende Kamerabild (Abbildung (74), die gleichen 600 Scanlines) des ultravioletten Spektralbereichs zeigt deutlich, daß das Bild des 89 GHz-Radiometers nicht die komplette Ausdehnung des Ölfilms (linker Bereich) erfaßt, der hier im UV-Bild etwa den Bereich der Scanlines 250 bis 550 abdeckt.



Abbildung 74: UV-Kamerabild des Meßgebietes; links der Ölfleck, rechts das Schiff.

Im Bild der UV-Kamera erscheint der Ölfleck sehr deutlich und in voller Ausdehnung. Hier ist es allerdings nicht möglich, Aussagen über die Dicke des Öls zu gewinnen.

### 6.3.1 Offset-Korrektur

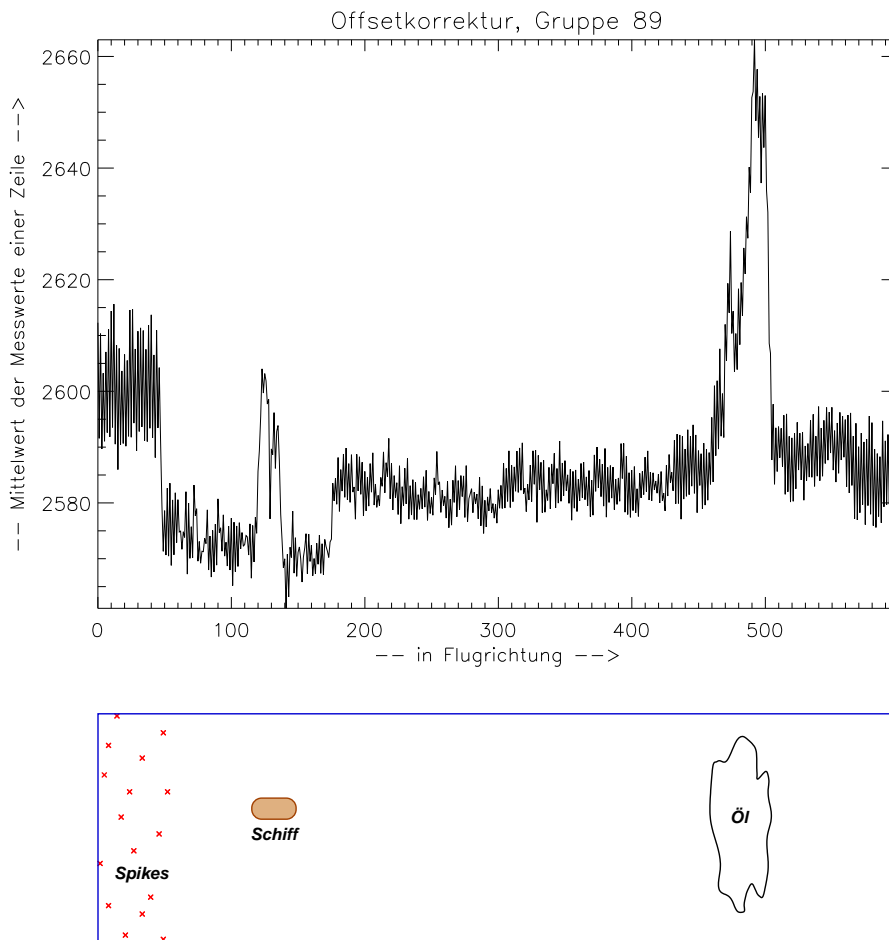


Abbildung 75: Reale Meßdaten, oben: H-Kanal (vordere und hintere 89 GHz-Meßgruppe), unten: Aufsicht auf das Meßgebiet

Abbildung (75) zeigt die Meßdaten des H-Kanals. Das Signal besteht aus alternierenden Werten der vorderen und hinteren Meßgruppe (vergl. Abbildung (71), rechts). Im folgenden soll nun der Offset der Meßwerte eliminiert werden.

Da die Meßwerte alternierend von zwei verschiedenen Antennen stammen, ist es sinnvoll, den Datensatz zunächst aufzuteilen:




Abbildung 76: Aufgeteilte Meßdaten des H-Kanals; links von der vorderen Antenne, rechts von der hinteren Antenne

In Abbildung (76) erkennt man deutlich Sprünge in den Meßwerten, die durch die regelmäßige Kalibrierung der Meßapparatur verursacht werden. Diese Parameterkorrektur erfolgt etwa alle 64 Meßzeilen während der Messung und führt u.a. zu den erkennbaren Offsetverschiebungen.

Die Offsets werden nun für jede Antenne abschnittsweise (je 64 Werte) korrigiert. Abbildung (77) zeigt das Ergebnis.




Abbildung 77: Aufgeteilte Meßdaten des H-Kanals nach der Offset-Korrektur; links von der vorderen Antenne, rechts von der hinteren Antenne

Schließlich werden die Daten der vorderen und hinteren Meßgruppe wieder zusammengefügt. In Abbildung (78) ist der Datensatz dargestellt, der später in das INF eingekoppelt wird.




Abbildung 78: Alternierend zusammengefügte Daten beider Meßgruppen. Die Meßwerte zu dieser Kurve werden später als Signal der H-Antenne betrachtet.

Das erhaltene Signal ist nun weitgehend offsetfrei. Den Offset an jedem Meßpunkt ganz zu eliminieren ist problematisch, da dann negative Meßwerte auftreten. Dennoch hebt sich das Signal des Ölflecks auf der rechten Seite deutlich vom Rauschen der Umgebung ab.

Auf der linken Seite kann man ebenso deutlich einen Peak erkennen, der durch das Schiff verursacht wird, welches das Öl verteilt hat.

Zur Bestimmung der Ölmenge würde man hier den Schiffsbereich  $[0; 200]$  herausnehmen. Zur Demonstration der Leistungsfähigkeit des INFs wird er hier aber zunächst nicht abgeschnitten.

Analog wird mit den Meßwerten der M- und L-Kanäle verfahren.

### 6.3.2 Winkelabhängigkeit

Wie bereits in Abbildung (73) erkennbar war, existiert eine Abhängigkeit der Meßwerte vom Scanwinkel. Diese führt zu einer Erhöhung der Meßwerte zu den Rändern des Meßstreifens hin.

Diese Winkelabhängigkeit tritt bereits bei einer Nullmessung ohne vorhandenes Öl auf der Wasseroberfläche auf und wirkt sich am jeweiligen Meßpunkt wie ein Offsetfehler aus.

Zur automatischen Korrektur benötigt man zunächst die Parameter der winkelabhängigen Offsetkurve. Diese gewinnt man zweckmäßigerweise in einem Bereich, wo lediglich das Hintergrundrauschen vorliegt (Nullmessung).




Abbildung 79: Zur winkelabhängigen Offsetkorrektur. Links: Summe über die Meßwerte der einzelnen Scanlines, rechts: mittlere Meßwerte pro Scanspalte im Kalibrierbereich (Zeilen 200 bis 400).

Zur Festlegung des Kalibrierbereichs ist in Abbildung (79) wieder die Summe der einzelnen Scanlines dargestellt. Die Offsetkorrektur aus Abschnitt 6.3.1 wurde bereits vorgenommen. Die winkelabhängigen Offsets bleiben davon jedoch unberührt.

Im Bereich der Scanlines 200...400 (Abbildung (79), links) wird kein Meßobjekt erfaßt. In diesem Bereich kann man die Winkelabhängigkeit direkt untersuchen; er wird daher im folgenden als *Kalibrierbereich* bezeichnet.

In rechten Diagramm von Abbildung (79) sind die Werte aufgetragen, die sich durch Mittelung über alle Scanlines des Kalibrierbereichs ergeben. Dabei wird diesmal nicht über die Zeilen (Scanlines) gemittelt, sondern über die Spalten (d. h. in Flugrichtung).

Anschließend wird durch die gefundene Kurve eine Parabel gelegt, deren Parameter sich direkt bestimmen lassen.

Es gilt die allgemeine Parabelgleichung  $y = q(x - c)^2 + h$ . Hierbei ist der Punkt  $(c, h)$  der Scheitelpunkt und  $q$  ein Streckungsfaktor der Parabel. Den Zahlenwert für  $h$  kann man direkt dem rechten Diagramm in Abbildung (79) entnehmen.

Die beiden Punkte  $(0, y_L)$  und  $(135, y_R)$  kann man am linken und rechten Rand des Diagramms ablesen. Durch Einsetzen in die Parabelgleichung erhält man 2 Gleichungen für die beiden Unbekannten  $c$  und  $q$ . Schließlich erhält man als allgemeine Lösung

$$y = \frac{135 (y_L - h)}{(y_L - y_R)} \pm \frac{135}{(y_L - y_R)} \sqrt{(y_L - h)^2 - (y_L - h)(y_L - y_R)} . \quad (50)$$

Die gefundene Parabelkurve wird von jeder einzelnen Scanline subtrahiert. Es treten dabei einige wenige negative Werte auf, da die Parabelkurve nur eine Näherung an die bereits gemittelten Meßwerte im Kalibrierbereich ist. Es handelt sich hier jedoch nur um einzelne isolierte Ausreißer, die durch eine Begrenzung des Wertebereichs auf positive Werte eliminiert werden können.




Abbildung 80: Meßdaten des L-Kanals nach der Vorverarbeitung.

In Abbildung (80) ist schließlich der Datensatz der L-Antenne nach der Vorverarbeitung dargestellt.

Im hinteren Bereich erkennt man die Amplitudenerhöhung durch das Öl. Vorne gibt es einen einzelnen größeren Peak in der Mitte, den ein Schiff im Meßbereich verursacht hat. Ganz vorn erkennt man eine große Zahl von Spikes, die das Meßsignal als Störung überlagern.

#### 6.4 Ergebnisse der INF-Verarbeitung

Die nachfolgenden Bilder stellen jeweils die Daten vor und hinter der Vorverarbeitungsstufe dar. Auf der linken Seite von Abbildung (81) sind jeweils die Eingangsdaten dargestellt, wie sie auf den drei Sensorkanälen gemessen wurden. Auf der rechten Seite sind zum direkten Vergleich die Ausgangsdaten der Vorverarbeitungsstufen abgebildet.

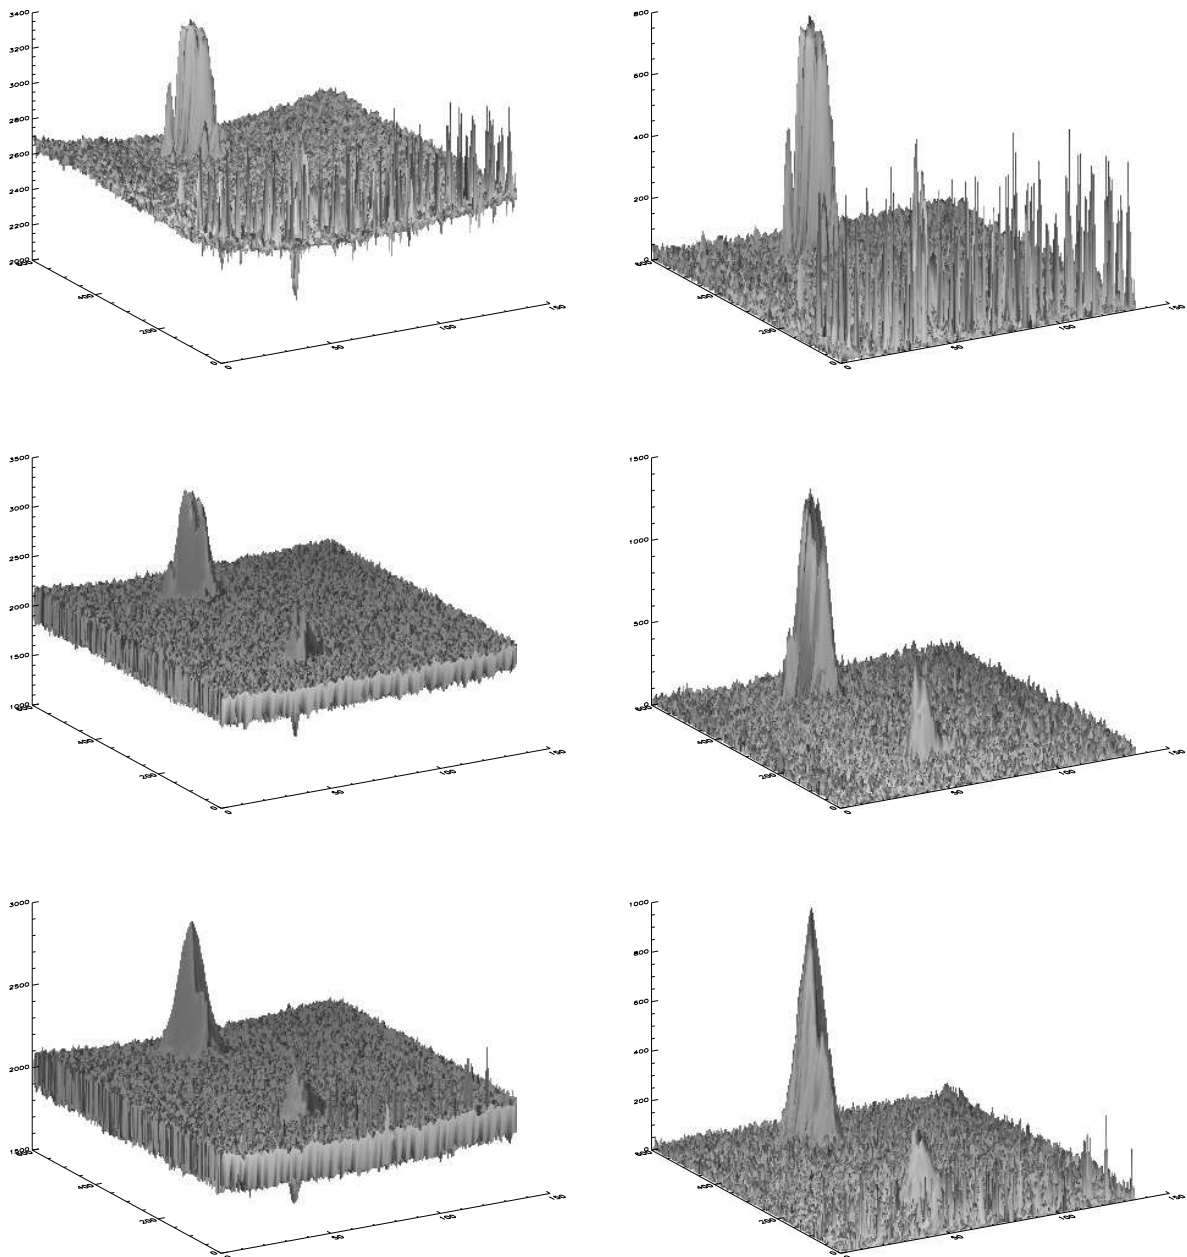


Abbildung 81: Wirkung der Offsetkorrektur auf die Meßdaten der H- (oben), M- (mittig) und L-Kanäle. Auf der linken Seite sind jeweils die Eingangsdaten dargestellt, auf der rechten Seite die Ausgangsdaten der Vorverarbeitung.

Die Flächen auf der linken Seite von Abbildung (81) erscheinen dicker, weil sie sich alternierend aus den Datensätzen beider Sensorgruppen zusammensetzen, deren Offsets unterschiedlich kalibriert sind.

Nach der Offsetkorrektur (Abbildung (81), rechts) tritt dieser Effekt nicht mehr auf (da die Offsets korrigiert wurden).

Die so gefundenen Antennenwerte werden nun zur weiteren Störungsreduktion mit dem INF bearbeitet.

Die Startwerte für das INF werden wie in den vorangegangenen Abschnitten exemplarisch als Mittelwerte der drei Antennen (Abbildung (81), rechts) gewählt. Die Startverteilung, die sich hierdurch ergibt, ist in Abbildung (82) dargestellt.




Abbildung 82: Startwerte des INFs

Die obere Fläche zeigt einen horizontalen Schnitt in Höhe eines Temperaturwertes von 50. Die Störungen im vorderen Teil des Meßgebietes kann man in der Schnittfläche besonders gut erkennen.

Die Parameter des INFs wurden anschließend heuristisch bestimmt. Ein optimaler Parametersatz sollte die Störungen dämpfen und gleichzeitig die eigentlichen Meßdaten möglichst wenig beeinflussen. In diesem Sinne liefert folgender Parametersatz gute Ergebnisse:

Parameter:	$\tau$	$\sigma_A$	$\sigma_N$	$r_N$	$\eta_N : \eta_A$
Wert:	10	60	100	5	9 : 1

Tabelle 6: Gewählte Parameter für die realen Meßdaten




Abbildung 83: Zustand des INFs nach der ersten Iteration. Die Höhenlinien haben einen Abstand von je 100 Intensitätsstufen.

Nach der ersten Iteration erscheint das Rauschen in Abbildung (83) bereits stark gedämpft. Zahlreiche Spikes im vorderen Bereich sind aber noch vorhanden.




Abbildung 84: Zustand des INFs nach der zweiten Iteration




Abbildung 85: Zustand des INFs nach der dritten Iteration




Abbildung 86: Zustand des INF's nach der fünften Iteration

Nach lediglich fünf Iterationsschritten sind alle Spikes vollständig eliminiert worden. An den eingezeichneten Höhenlinien kann man erkennen, daß dabei das Maximum des eigentlichen Meßsignals (Ölbereich) nur um rund 10 % gedämpft wurde.

Das Integral über alle Meßwerte ist ebenfalls kleiner geworden. Gegenüber den Startwerten hat es nach der fünften Iteration aber lediglich um 7,8 % abgenommen.

Im vorderen Teil von Abbildung (86) erkennt man gut die Position und Orientierung des Schiffes.

Durch Integration läßt sich außerdem das Volumen unterhalb der Kurve bestimmen. Wenn man die Temperaturverteilung nun direkt als Öldicke interpretieren könnte, wäre hieraus die Bestimmung der Ölmenge möglich. Bei

bekanntem Ölvolumen  $V_{\text{Öl}}$  (Kalibriermessung) wird zunächst über die Gleichung

$$V_{\text{Öl}} \stackrel{!}{=} \mu_T \cdot \int_y \int_x m(x, y) \, dx \, dy \quad (51)$$

ein vom Öltyp (Rohöl, Schweröl, etc.) abhängiger Kalibrierfaktor  $\mu_T$  bestimmt<sup>44</sup>. Bei der hier dargestellten Messung wurden  $V_{\text{Öl}} = 15 \text{ m}^3$  Öl verteilt. Dies liefert (unter Voraussetzung der direkten Interpretierbarkeit der Meßwerte als "Dicken") einen Kalibrierfaktor von

$$\mu_{\text{crude oil}} = 0,0158 \text{ .} \quad (52)$$

Um das Rauschen im nichtverschmutzten Wasserbereich deutlich zu reduzieren, wurde eine sehr starke Nachbarschaftsgewichtung gewählt ( $\eta_N : \eta_A = 9 : 1$ ). Es besteht dabei prinzipiell immer die Gefahr, daß die Signalbereiche auseinanderlaufen und dabei flacher werden. Dies geschieht auch im vorliegenden Fall und wird nach einigen weiteren Iterationen deutlich. Abbildung (87) zeigt hierzu die Verteilung nach 20 Iterationen.




Abbildung 87: Links: Zustand des INFs nach 20 Iterationen. Rechts: Entwicklung des Integrals über alle Meßwerte

Wie man anhand Abbildung (87, rechts) erkennen kann, verläuft der Wert für das Integral über alle Meßwerte entsprechend einer fallenden  $e$ -Funktion.

<sup>44</sup>Die Meßfläche muß dabei auf den Bereich des Öls begrenzt werden, damit das Schiff nicht mit erfaßt wird.

Damit konvergiert das INF zwar gegen einen stabilen Zustand, allerdings wird dabei die Verteilung stark deformiert<sup>45</sup>. Man muß daher die Iterationen nach einer festgelegten Schrittzahl abbrechen, die z. B. im voraus definiert werden kann.

## 6.5 Erweiterungsmöglichkeiten

### 6.5.1 Korrektur von Mehrdeutigkeiten

Ein besonderes Merkmal des vorgestellten INFs ist dessen Fähigkeit, mit mehrdeutigen Eingangsdaten arbeiten zu können. In [28] wurde ein physikalisches Meßmodell vorgeschlagen, daß auf der Annahme von Interferenzeffekten bei der Reflektion an den Grenzschichten Luft–Öl–Wasser beruht (vergl. [29], [27]).

Da sich in den vorliegenden realen Meßdaten keine Mehrdeutigkeiten zeigen, wird in diesem Abschnitt auf Beispielrechnungen verzichtet.

In Abbildung (88) ist der theoretische Kurvenverlauf für die Zunahme der gemessenen Temperatur in Abhängigkeit von der Öldicke dargestellt. Die drei Kurven entsprechen den drei Radiometern, wobei die Kurve der größten Wellenlänge dem 18 GHz–L–Kanal zugeordnet ist.

Jeder Radiometer–Meßfrequenz entspricht nach  $\lambda = \frac{c}{f}$  eine bestimmte Wellenlänge. Man erhält von jedem einzelnen Radiometer eindeutige Meßwerte, solange nur Dicken im Bereich  $[0; \frac{1}{4}\lambda]$  gemessen werden. In Abbildung (88) entspricht dies dem Bereich zwischen 0 mm (kein Öl) und dem ersten Maximum der jeweiligen Sinuskurve ( $\frac{1}{4}\lambda$  mm).

---

<sup>45</sup>Aufgrund der starken Nachbarschaftswechselwirkung konvergiert hier letztlich  $m(x, y)_t \xrightarrow{t \rightarrow \infty} 0$  für alle  $m(x, y)$ . Dieser Zustand ist zwar stabil, aber nicht weiter auswertbar.




Abbildung 88: Theoretisch erwarteter Kurvenverlauf für die Helligkeitstemperaturzunahme in Abhängigkeit von der Öldicke  $d$  (Millimeter) in den drei Frequenzbereichen (89 GHz: gestrichelt, 36,5 GHz dünn und 18,7 GHz dick durchgezogen dargestellt). Simulation aus [28].

Im folgenden Abschnitt soll nun gezeigt werden, daß die neuronale Dynamik die Mehrdeutigkeiten auf sehr elegante Weise kompensieren kann.

In Abschnitt 4.4 wurde eine neuronale Dynamik vorgestellt, mit der sich Ausreißer in den einzelnen Sensorwerten zu einem Meßpunkt eliminieren lassen. Der Meßwert jedes Sensors generierte dort einen Attraktor auf der Dickenachse:




Abbildung 89: Meßwerte und Attraktoren

Man erweitert nun das System so, daß zusätzlich auch Attraktoren für alle weiteren Dickenwerte erzeugt werden, die den gleichen Sensorwert liefern könnten. Das Resultat ist in Abbildung (90) dargestellt.




Abbildung 90: Mehrfache Attraktoren pro Meßwert

Abbildung (90) zeigt, daß der Meßwert  $m_1$  der ersten Antenne (Meßwellenlänge  $\lambda_1$ ) nicht nur einen Attraktor für die Dicke  $m_1$  erzeugt, sondern periodisch noch weitere Attraktoren für die Dicken

$$m_{1,k} = m_1 + k \cdot \frac{\lambda_1}{4} \quad k \in \mathbb{N} \quad . \quad (53)$$

Wie in Abschnitt 4.4 beschrieben wurde, ist jedem Attraktor eine gewisse Reichweite über seinen  $\sigma_A$ -Parameter zugeordnet. Die Wirkung der einzelnen Attraktoren in Abbildung (90) überlagert sich also zu einer Gesamtfunktion, deren höchste Maxima dort auftreten, wo mehrere Einzelattraktoren dicht beieinander liegen.

### 6.5.2 Laterale Inhibition im INF

Zur Verbesserung der Ortsauflösung wäre eine Rückfaltung der Antennentransformation günstig. Leider ist eine solche Rücktransformation nicht möglich, da die Signale der Antennen mit einem Rauschanteil überlagert sind (vergl. [22]). Man ist deshalb auf Näherungsverfahren angewiesen (vergl. [23]). Eine andere Wahl der Nachbarschaftsgewichtung liefert hierzu evtl. eine brauchbare Approximation der Rücktransformation.

Durch die Verwendung einer anderen Gewichtsfunktion mit negativen Anteilen kann man eine laterale Inhibition der Neuronen erreichen. Hierdurch verdichtet sich die INF-Aktivität auf die Bereiche hoher Aktivität, bei gleichzeitiger Dämpfung der Umgebung.

Das hier benutzte INF repräsentiert die Realität nur im Sinne der gemessenen Werte. Eine hemmende Wirkung der Nachbarschaftsneuronen führt dagegen zu einer Transformation der Meßwertverteilung, die eventuell besser den realen Dickenwerten (und insbesondere dem realen Ölvolumen) entspricht. Eine weitere Untersuchung zur INF-basierten Rücktransformation geht erheblich über den Rahmen dieser Arbeit hinaus, erscheint aber an dieser Stelle durchaus sinnvoll.

### 6.5.3 Hinzunahme weiterer Meßdatenquellen

Die vorgestellte Meßdatenverarbeitung mit einem INF fusioniert zweidimensional verteilte Meßdaten weitgehend unabhängig von der Datenquelle. Es ist dadurch möglich, weitere Sensordaten in das Feld einzukoppeln, die von Sensoren auf ganz anderen Frequenzbändern gemessen wurden. Ein typisches Beispiel wäre etwa die Hinzuziehung eines Infrarot-Kamerabildes. Das Kamerabild liefert ebenfalls eine zweidimensionale Temperaturverteilung, die darüber hinaus eine sehr gute Ortsauflösung bietet.

Als weitere Verbesserung bietet es sich an, ein sogenanntes *Preshape* zu verwenden. Als *Preshape* bezeichnet man ein Verteilungsmuster, das bereits am

Anfang der Verarbeitung eine (ggf. grobe) Aktivitätsverteilung im INF herstellt. Bei den hier verwendeten realen Daten kann man hierzu etwa das Bild der UV-Kamera benutzen, die ebenfalls am Flugzeug montiert ist.

Das UV-Bild liefert zwar kaum eine quantitative Dickeninformation, jedoch kann man deutlich die Gesamtausdehnung eines Ölteppichs erkennen (vergl. Abbildung (74)). Ein Ölfilm ist bereits ab einer Schichtdicke von  $0,1 \mu m$  erkennbar ([38]). Aufgrund der Abhängigkeit vom Sonnenlicht ist die Anwendung des UV-Kanals allerdings auf den Tag beschränkt und erfordert gute Sichtbedingungen.

## 6.6 Vergleiche mit anderen Verfahren

### 6.6.1 Einfache Mittelung

Daß die hier vorgestellte Meßdatenverarbeitung mit einem INF bessere Ergebnisse liefert als eine einfache Mittelung, muß hier nicht extra untersucht werden: die Mittelwerte der Sensoren wurden jeweils zur Initialisierung des INFs benutzt. Man kann entsprechende Werte zum Qualitätsvergleich daher direkt dem Anfangszustand des INFs entnehmen.

Die Verarbeitungsleistung des INFs beinhaltet in dieser Arbeit somit in jedem Fall bereits eine einfache Mittelwertbildung. Die Verbesserung, vor allem durch die Nachbarschaftswechselwirkung, wurde in den vorangegangenen Abschnitten sowohl qualitativ wie auch quantitativ untersucht und dargestellt.

### 6.6.2 Neuronale Netze

Neuronale Netze können ebenfalls benutzt werden, um die vorliegenden Sensordaten eines Meßpunktes zu einem einzelnen Meßwert zu fusionieren. In der erforderlichen Trainingsphase eines derartigen Netzes werden jedoch Informationen über die jeweils tatsächlich vorliegende Verteilung

benötigt, da Neuronale Netze in einem sogenannten *überwachten* Lernverfahren (vergl. [12]) trainiert werden müssen<sup>46</sup>.

Die Lernphase muß außerdem für jede auftretende Wetterlage neu durchlaufen werden, da sich die Qualität der von den Sensoren erhaltenen Meßwerte z. B. durch Regen verändert.

Gegenüber einem INF hat das Neuronale Netz jedoch den Nachteil, daß es jeweils nur die Meßwerte an einem einzelnen Meßpunkt fusioniert. Eine Berücksichtigung der umliegenden Meßwerte findet dabei nicht statt.

Die im Lernprozeß vom Neuronalen Netz ermittelte Abbildung der Meßdaten  $\vec{m}$  auf einen einzelnen Meßwert  $m$  läßt sich bei den Neuronalen Feldern durch die Gewichtsfunktionen  $\vec{v}(m)$  (vergl. Abbildung (34) auf Seite 55) repräsentieren. Die Nutzung der vom Neuronalen Netz gefundenen Übertragungskennlinien setzt jedoch voraus, daß die innere Struktur des Neuronalen Netzes hinreichend einfach ist (z. B. nicht mehr als ein *Hidden Layer*), da man dessen Gewichtungen sonst nicht direkt als  $\vec{v}(m)$  interpretieren kann.

---

<sup>46</sup>Die Gewichtungen, die in einem Neuronalen Netz auftreten, werden in jedem Lernschritt so variiert, daß die Ist-Antwort des Netzes jeweils mit einer bekannten Soll-Antwort übereinstimmt.

## 7 Zusammenfassung

In der vorliegenden Arbeit wurden Instantiierte Neuronale Felder (INF) als ein neues Verfahren zur Lösung eines Sensorfusionsproblems vorgestellt. INFs unterscheiden sich von anderen Neuronalen Feldern ([1]) in erster Linie dadurch, daß die betrachtete Systemvariable in allen Punkten des Feldes stets je einen einzelnen, eindeutigen Wert annimmt. Durch diese Modifikation konnte der enorme Rechenaufwand, den allgemeine Neuronale Felder sonst bedingen, deutlich reduziert werden.

Auf synthetischen Testdaten wurde gezeigt, daß man die Komplexität des INFs je nach Anforderung modular erhöhen kann. Durch das schrittweise Hinzufügen einzelner Iterationsterme zur Iterationsregel der einzelnen Feldneuronen konnte das Verhalten des INFs an die jeweils vorliegenden Störungsverhältnisse angepaßt werden.

Zur quantitativen Untersuchung der jeweils vorgenommenen Erweiterungen wurden zwei Fehlermaße eingeführt, deren Werte einen Vergleich verschiedener Iterationsterm-Varianten erlauben. Die Fehlermaße gestatten es, Aussagen über die Güte der Fehlerunterdrückung im INF zu treffen.

Die Parameter, die in den Iterationstermen auftreten, wurden einzeln identifiziert, beschrieben und unter Benutzung der Fehlermaße diskutiert. Hierbei ergaben sich einige einfache Regeln zur Einschränkung der Parameterwahl.

Das so entwickelte INF wurde anschließend zur Bearbeitung realer Meßdaten herangezogen. In diesem Zusammenhang wurde die verwendete Meßapparatur beschrieben. Die Kenntnis der Meßprozedur gestattete die Einbringung von Vorwissen in die Meßdatenverarbeitung, was zu einer einfachen Vorverarbeitungsstufe zur Offsetkorrektur führte.

## 8 Ergebnisse

Das vorgestellte Verfahren konnte auf den simulierten Testdaten stochastisch verteilte Fehler bis zu einer Größenordnung von etwa 15 % verkraften. Treten hohe Fehleranteile nur auf wenigen Meßkanälen auf, so beeinflussen diese auch bei sehr hohen Rauschanteilen die Ergebnisse nur geringfügig.

Das INF entscheidet in Abhängigkeit von den jeweiligen Sensorwerten selbständig und ohne vorherige Trainingsphase, welche Sensoren verwendbare Werte liefern und welche Sensorwerte als Ausreißer zu betrachten sind. Sensorwerte, die als Ausreißer erkannt wurden, werden weitgehend ignoriert und haben daher keine negative Wirkung auf das Ergebnis.

Im Gegensatz zu klassischen Verfahren der Meßdatenverarbeitung kann das INF somit Spikes auf einzelnen Meßkanälen erkennen und durch den verwendeten dynamischen Ansatz eliminieren. Die Dämpfung von Rauscheinflüssen erfolgt durch die Einbeziehung einer Nachbarschaftswechselwirkung. Letztere erlaubt auch die Korrektur von Störungen, die synchron auf allen Meßkanälen auftreten.

Auf diese Weise konnte das INF die Schichtdickenverteilungen sehr genau reproduzieren, die den Simulationen zugrunde lag. Dies ist umso bemerkenswerter, da bisher nur die Sensordaten selbst und die Nachbarschaftswechselwirkung als Terme in den Iterationsregeln des INFs genutzt wurden.

Die modulare Struktur des INFs erlaubt die Hinzunahme weiterer Iterationsterme in Abhängigkeit von der jeweils vorliegenden Fehlerkomplexität. Die Meßdatenverarbeitung mit INFs ist deshalb ein sehr konstruktives Verfahren. Im Gegensatz zu anderen Verfahren ist es damit relativ einfach, vorhandenes Vorwissen mit in die Konstruktion des INFs einfließen zu lassen.

Mit den realen Meßdaten konnte die Leistungsfähigkeit des INFs deutlich demonstriert werden. Da eine Trainingsphase (wie etwa bei neuronalen Netzen) bei einem INF nicht erforderlich ist, konnten die INF-Parameter hier direkt und interaktiv gewählt werden. Das beschriebene INF war bei den

realen Daten in der Lage, die Störungseinflüsse fast vollständig zu unterdrücken, ohne die in den Daten enthaltene, eigentliche Information wesentlich zu verändern.

Da zur Zeit noch kein physikalisches Modell vorliegt, das die Interpretation der Wärmeverteilung als Dickenverteilung erlaubt, konnte eine Bestimmung der real vorliegenden Ölmengen noch nicht vorgenommen werden. Mit einem plausiblen Modell sollte dies jedoch in der Zukunft auf Basis der INF-Ergebnisse möglich sein.

Die Modularität des vorgestellten Lösungsansatzes zur Sensorfusion erlaubt schließlich auch noch die Nutzung weiterer Datenquellen, z. B. Kamerabilder. Durch das Hinzufügen weiterer Terme zu den verwendeten Iterationsregeln können diese nahtlos in die Struktur des INFs integriert werden. Hierbei ist es im Gegensatz zu vielen anderen Verfahren nicht erforderlich, dass alle Sensordaten von Sensoren des gleichen Typs stammen. Es ist vielmehr einfach möglich, Sensordaten von Kameras, Radar, Mikrowellenradiometern und Fluorosensoren zu einer einzigen Dickeverteilung zu fusionieren.

## 9 Ausblick

In Abschnitt 4.5 wurde eine Möglichkeit aufgezeigt, die Sensorfusion durch den Einsatz von Vertrauensfaktoren  $\vartheta_i$  weiter zu verbessern. Die Wahl dieser Vertrauensfaktoren ist jedoch problematisch, da z. B. Witterungseinflüsse eine Rolle spielen.

Obwohl sich die INF-Parameter in weiten Bereichen vorwählen lassen, sollte man außerdem erwägen, ein einfaches Lernverfahren zu implementieren, das anhand von Simulationsdaten jeweils einen optimalen Parametersatz bestimmen kann. Ergänzend wäre auch eine graphische Benutzeroberfläche für die INF-Software wünschenswert, die eine interaktive Parameteroptimierung gestattet.

Ebenso lohnend erscheint die Einbeziehung weiterer Sensorkanäle, speziell der Kameras (UV- und IR-Bereich). Auch wenn z. B. die UV-Kamera keine quantitative Dickeninformation liefern kann, liefert sie doch (zumindestens bei Tageslicht) sehr genaue Daten über die geometrische Ausdehnung einer Ölverschmutzung. Diese Information kann als sog. *Preshape* ([32], [33]) in das INF eingekoppelt werden und auf diese Weise die Robustheit gegenüber Störungen noch weiter erhöhen.

Das hier vorgestellte INF wurde zum Einsatz in einem ökologischen Kontrollsystem entwickelt.

Abbildung (91) zeigt den gewünschten Aufbau der Meßkette, wie er zur ökologischen Umweltüberwachung auf freier See vorgesehen ist. Die Meßdaten am Eingang werden vorverarbeitet und dann mit dem INF ausgewertet. Hierbei kommen verschiedenste Sensoren und Meßverfahren zum Einsatz. Das INF liefert anschließend eine topologische Karte der Ölverschmutzung. Hierzu ist jedoch noch ein Modell erforderlich, das die Schichtdicken in Abhängigkeit von den festgestellten Sensorwerten beschreibt.

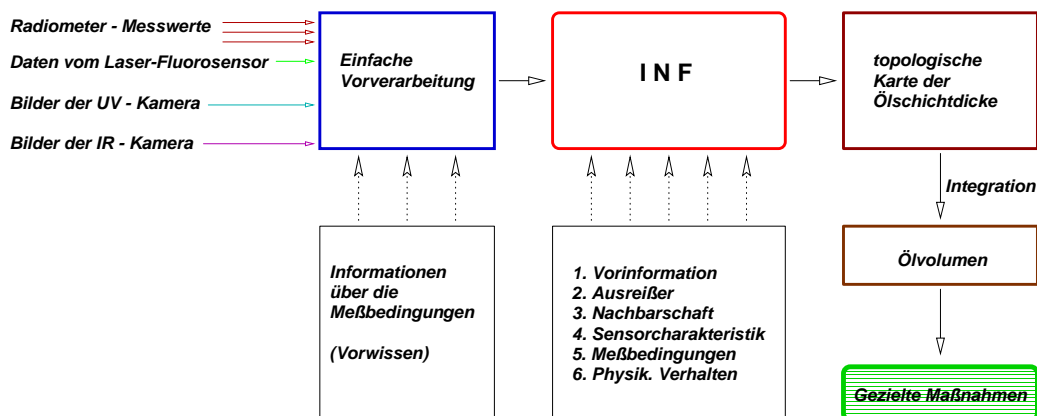


Abbildung 91: Darstellung der geplanten Meßkette

Durch Integration kann man schließlich die gesamte Ölmenge bestimmen, die sich als Ölteppich auf dem Meer ausgebreitet hat. Bei genauer Kenntnis von Ölvolumen und Ölausdehnung lassen sich anschließend gezielte Bekämpfungsmaßnahmen ergreifen.

Neben der Anwendung im vorgestellten Umweltkontrollsystem eignen sich *Instantiierte Neuronale Felder* als universelles Sensorfusionsverfahren für eine Vielzahl weiterer Gebiete.

Die modulare Struktur, verbunden mit der Möglichkeit, Sensordaten von unterschiedlichen Sensortypen zu fusionieren, ermöglicht ebenso den Einsatz in der Medizin (etwa zur Auswertung bildgebender Untersuchungsverfahren). Die INF Anwendung ist dabei keineswegs auf Bilddaten beschränkt, sondern überall nutzbar, wo eine Meßgröße aus mehreren einzelnen Meßwerten bestimmt werden muß.

## A Nomenklatur

### Indizes

Index	Mnemonik	bezieht sich auf...
$H$	high	die Antenne der höchsten Frequenz
$M$	medium	die Antenne der mittleren Frequenz
$L$	low	die Antenne der niedrigsten Frequenz
$Sp$	Spikes	Spike-Parameter (Anzahl, Höhe)
$sat$	saturation	Sättigung
$A$	Antenne	Antennenterme
$N$	Nachbarn	Nachbarschaftsterme
$k$		Element einer Menge
$in$	Input	Eingangsdaten
$out$	Output	Ausgabedaten
$T$	Typ	Öltyp
$i$		Sensornummer
$r$		Rauschgröße

### Funktionen

Bezeichner	Mnemonik	bezieht sich auf...
$w(r)$	weight	eine allgem. Gewichtsfunktion
$g(r)$	Gewicht	eine Gewichtsfunktion für Nachbarschaften
$G(r)$	Gauß	eine Gauß'sche Glockenfunktion
$r(t)$	Rauschen	eine Rauschfunktion
$s(t)$	Signal	eine allgem. Signalfunktion
$\vartheta(m, \vec{r})$	trust	einen Vertrauensfaktor
$E\{\}$		den Erwartungswert-Operator

**Variablen und Bezeichner**

Bezeichner	Mnemonic	bezieht sich auf...
$r, R, \vec{r}$	Radien	Radien
$A$		Offsets
$\alpha$	Alpha	Rauschanteile
$\alpha_r$		Betragsmaximum einer Rauschfunktion
$N$		eine Anzahl
$N_M$		eine Anzahl Meßwerte
$N_{ij}$	Neuron	ein Neuron an der Position $(i, j)$
$D$		Amplituden
$U$		Erregung oder Sättigung
$\mathbf{ID}$		eine Menge von Nachbarn
$\lambda$		Wellenlängen
$\vartheta$	trust	Vertrauensfaktor
$\Theta_S$	scan	den gesamter Abtastwinkel
$m$		einen allgemeinen Meßwert
$\bar{m}$		einen arithm. Mittelwert
$m_0$		realer Wert einer physikal. Größe
$\sigma^2$		Varianz einer Gaußverteilung
$\mu_x, \mu_y$		Mittelpunktskoordinaten
$t$	time	die Zeit
$P$	power	eine Leistungsgröße
$\epsilon$		ein Fehlermaß
$V$	Volumen	Volumina (insbes. des Öls)
$x$		karthesische Koordinate quer zur Flugrichtung
$y$		karthesische Koordinate in Flugrichtung
$\mu_T$	Typ	Öltyp abhängiger Kalibrierfaktor

## B Elektrischer Aufbau der Meßkanäle

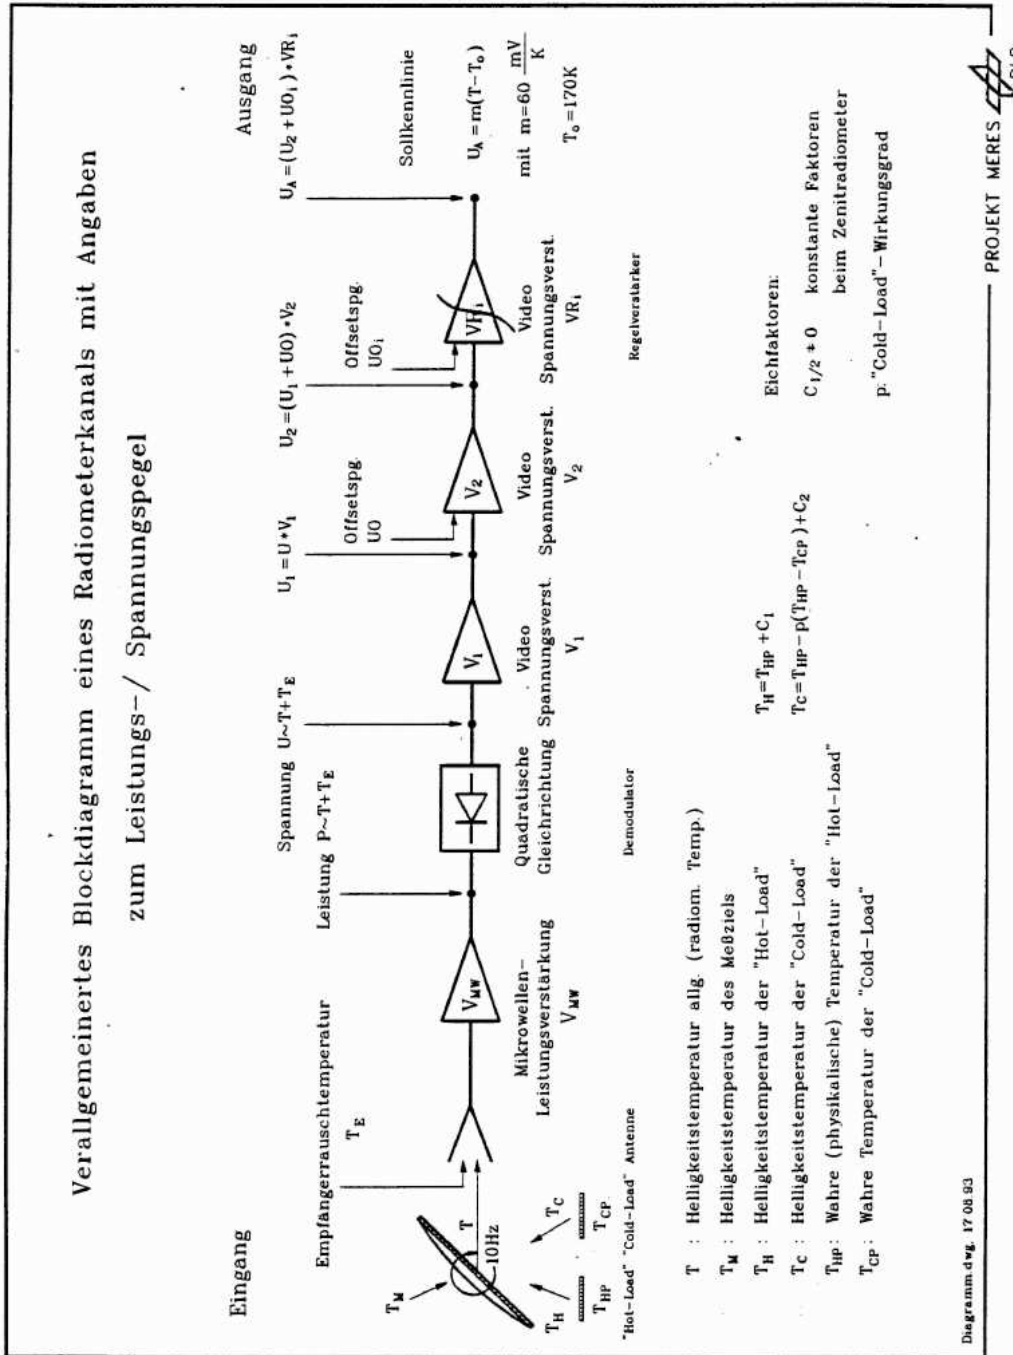


Abbildung 92: Elektrischer Aufbau der Meßkanäle (aus [28])

## C INF Simulationsprogramm

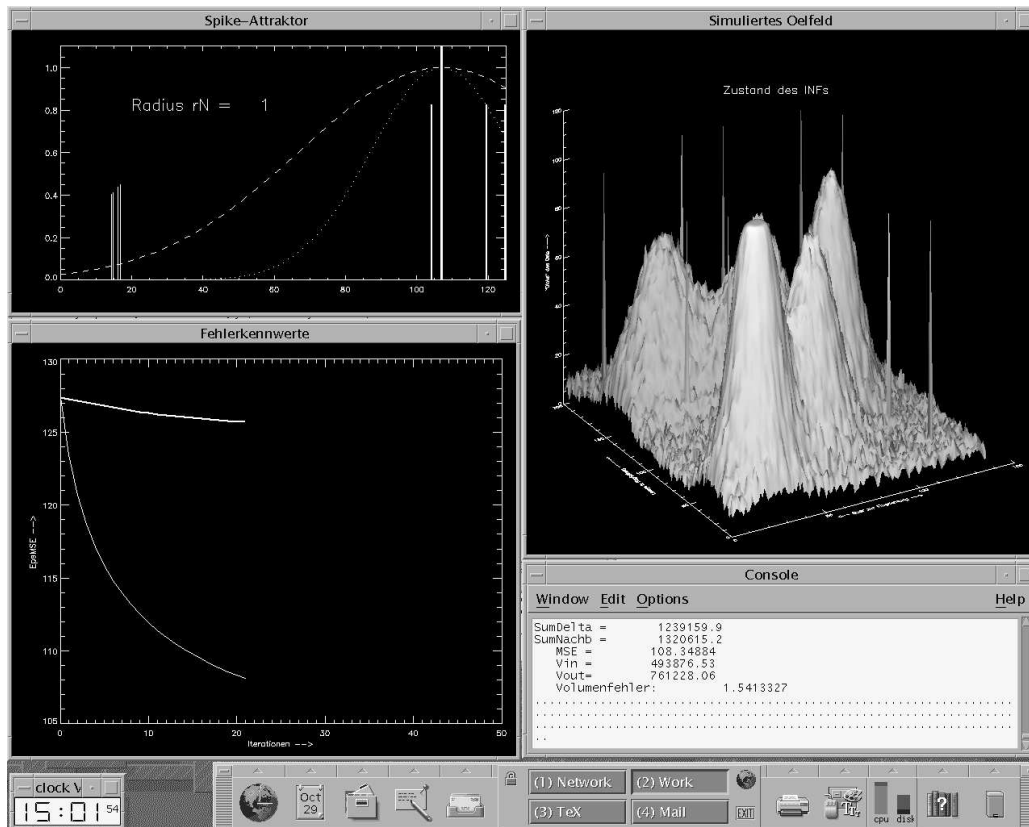


Abbildung 93: Bildschirm-Hardcopy des erstellten Softwaresystems

Abbildung (93) zeigt ein Bild der Entwicklungsumgebung (SUN X11/Motif). Das obere Window auf der linken Seite zeigt das Attraktordiagramm an einer Spike-Position. Darunter ist die Entwicklung der Fehlerkennwerte  $\epsilon_{MSE}$  (untere Kurve) und  $\epsilon_V$  (obere Kurve) dargestellt. Die Kurve für  $\epsilon_V$  wird dabei automatisch so skaliert, daß sie in dieser Abbildung gut erkennbar ist. Das Window oben rechts zeigt den aktuellen Zustand des INFs. Im Protokollfenster unten rechts kann man den Fortgang der Rechnung beobachten.

Das Listing wurde um alle Postscript-erzeugenden Teile gekürzt und liegt hier in der nicht-optimierten Version vor. Die in Abschnitt 4.6.4 vorgestellten Verbesserungen führen zwar zu erheblich kürzeren Laufzeiten, erschweren aber das Verständnis des IDL Programmcodes.

```

#####
#####
##### N'Oil: Simulation eines Instantiierten Neuronalen Feldes (INF) #####
##### zur multispektralen Sensorfusion #####
##### <C> 1998 cand. Ing. Kay Gorontzi #####
#####
#####
; =====
; Simulations-Parameter
; =====

R_H = 1.0 ; 2.0 ; Footprint-Radius (H-Antenne)
R_M = 2.5 ; 5.0 ; Footprint-Radius (M-Antenne)
R_L = 5.0 ; 10.0 ; Footprint-Radius (L-Antenne)

A_H = 0.0 ; Offset, H-Kanal
A_M = 0.0 ; Offset, M-Kanal
A_L = 0.0 ; Offset, L-Kanal

Alpha_H = 0.10 ; Rauschanteil, H-Kanal (% vom Maximalwert)
Alpha_M = 0.10
Alpha_L = 0.10

N_Sp = 1771 ; Abstand der Spikes
D_Sp = 0.50 ; Relative Amplitude der Spikes (%)

N_A = 562 ; Abstand der Ausreisser
D_A = 0.20 ; Relative Amplitude der Ausreisser (%)

U_Sat= 0.90 ; Sättigungsgrenze (% vom Maximalwert)

SigmaA = 20.0 ; Wirklich sigma_A
SigmaN = 40.0 ; 2 * (sigma_A)^2
tau = 28.0 ; tau
EtaA = 1.0 ; Gewichtung zwischen den beiden
EtaN = 10.0 ; Einflussternen
RadiusG = 5.0 ; Groesse der Nachbarschaftsumgebung

; =====
; Files (Input & Output)
; =====

MyInput= 'MAP.save' ; Input-Daten, z. B. '/home/tmp/gorontzi/Map05.save'

MyOutput='rN.LoopResults.save' ; Die Parameter-Ergebnisse, die pro Loop immer mehr werden
AttraktorenEPS='rN.attraktoren.eps' ; Die Attraktoren (Fenster oben links)
FehlerEPS='rN.fehler.eps' ; Die Fehlerkennwerte (Fenster unten links)
ScharEPS='rN.schar.eps' ; Die Parameterschar (Fenster oben rechts)
ZustandEPS='rN.INF.eps' ; Das INF am Ende eines LoopParameters

; =====
; Interne Parameter
; =====

MaxIterations = 50 ; Soviele Iterationen werden maximal durchgerechnet
MaxLoops = 20 ; Soviele Parameter werden durchgespielt

; =====
; Laden der sythetischen Oelflaeche
; =====

PRINT, "Loading..."
RESTORE, MyInput, /VERBOSE
PRINT, "OK."

PRINT, "Input" ; Geladene Verteilung anzeigen
SHADE_SURF, OilMap, /SAVE
CONTOUR, OilMap, /NOERASE, /T3D, NLEVELS=10 ; mit Hoehenlinien
WAIT, 1

; =====
; Die Fehlerwerte kommen in ein separates Window
; =====

WINDOW, 2, COLORS=2, RETAIN=2, TITLE='Spike-Attraktor', XSIZE=630, YSIZE=350
WINDOW, 1, COLORS=2, RETAIN=2, TITLE='Fehlerkennwerte', XSIZE=500, YSIZE=600, XPOS=125, YPOS=1
WINDOW, 0, COLORS=-128, RETAIN=2, TITLE='Simuliertes Oelfeld', XSIZE=630, YSIZE=650
WSET, 0
LOADCT, 0 ; Farbtabelle: b & w, linear

; =====
; Global gueltige Deklarationen
; =====

EpsMSE = DBLARR(301)
EpsV = DBLARR(301)

; =====
; Antennen - Abtastung
; =====

```

```

PRINT, "Abtastung"

; Die Abtastung erfolgt mit einer Gauss-Charakteristik,
; deren Parameter zunaechst bestimmt werden muessen.

Size      = ROUND(R_H * 4 + 1)          ; Size ist immer ungerade und daher gut zentrierbar
Antenne_H = DBLARR(Size, Size)
Sigma_H   = R_H / SQRT(ALOG(2))
TeilExp   = 1 / (-2 * Sigma_H * Sigma_H)
Sum_w_H   = 0.0

FOR y=0, Size-1 DO BEGIN
  yy = y - Size/2
  YY = YY * YY
  FOR x=0, Size-1 DO BEGIN
    xx = x - Size/2
    xx = xx * xx
    Rquad = xx + yy
    Antenne_H(x,y) = EXP(TeilExp * Rquad)
    Sum_w_H = Sum_w_H + Antenne_H(x,y)
  ENDFOR
  PRINT, FORMAT = "(A,$)", "."
ENDFOR

Size      = ROUND(R_M * 4 + 1)          ; Size ist immer ungerade und daher gut zentrierbar
Antenne_M = DBLARR(Size, Size)
Sigma_M   = R_M / SQRT(ALOG(2))
TeilExp   = 1 / (-2 * Sigma_M * Sigma_M)
Sum_w_M   = 0.0

FOR y=0, Size-1 DO BEGIN
  yy = y - Size/2
  YY = YY * YY
  FOR x=0, Size-1 DO BEGIN
    xx = x - Size/2
    xx = xx * xx
    Rquad = xx + yy
    Antenne_M(x,y) = EXP(TeilExp * Rquad)
    Sum_w_M = Sum_w_M + Antenne_M(x,y)
  ENDFOR
  PRINT, FORMAT = "(A,$)", "."
ENDFOR

Size      = ROUND(R_L * 4 + 1)          ; Size ist immer ungerade und daher gut zentrierbar
Antenne_L = DBLARR(Size, Size)
Sigma_L   = R_L / SQRT(ALOG(2))
TeilExp   = 1 / (-2 * Sigma_L * Sigma_L)
Sum_w_L   = 0.0

FOR y=0, Size-1 DO BEGIN
  yy = y - Size/2
  YY = YY * YY
  FOR x=0, Size-1 DO BEGIN
    xx = x - Size/2
    xx = xx * xx
    Rquad = xx + yy
    Antenne_L(x,y) = EXP(TeilExp * Rquad)
    Sum_w_L = Sum_w_L + Antenne_L(x,y)
  ENDFOR
  PRINT, FORMAT = "(A,$)", "."
ENDFOR
PRINT, ""

; Damit die Faltung auch am Rand funktioniert, muss man um die eigentlichen
; Daten einen hinreichend breiten Rand legen.

FrameBreite = Breite + R_L * 4
FrameLaenge = Laenge + R_L * 4
FrameX      = R_L * 2
FrameY      = R_L * 2
OilMapTmp   = DBLARR(FrameBreite, FrameLaenge)

PRINT, "** Antenne H"
OilMapTmp(*,*) = 0
OilMapTmp(FrameX:FrameX+Breite-1, FrameY:FrameY+Laenge-1) = OilMap(0:Breite-1,0:Laenge-1)
OilMapTmp = CONVOL(OilMapTmp, Antenne_H)
OilMap_H   = OilMapTmp(FrameX:FrameX+Breite-1, FrameY:FrameY+Laenge-1) / Sum_w_H

PRINT, "** Antenne M"
OilMapTmp(*,*) = 0
OilMapTmp(FrameX:FrameX+Breite-1, FrameY:FrameY+Laenge-1) = OilMap(0:Breite-1,0:Laenge-1)
OilMapTmp = CONVOL(OilMapTmp, Antenne_M)
OilMap_M   = OilMapTmp(FrameX:FrameX+Breite-1, FrameY:FrameY+Laenge-1) / Sum_w_M

PRINT, "** Antenne L"
OilMapTmp(*,*) = 0
OilMapTmp(FrameX:FrameX+Breite-1, FrameY:FrameY+Laenge-1) = OilMap(0:Breite-1,0:Laenge-1)
OilMapTmp = CONVOL(OilMapTmp, Antenne_L)
OilMap_L   = OilMapTmp(FrameX:FrameX+Breite-1, FrameY:FrameY+Laenge-1) / Sum_w_L

; =====
; Offset hinzufuegen
; =====

```

```

PRINT, "Offset"

OilMap_H = OilMap_H + A_H
OilMap_M = OilMap_M + A_M
OilMap_L = OilMap_L + A_L

PRINT, "Maximalwerte"

Grenze_H = U_Sat * MAX(OilMap_H)      ; Das brauchen wir erst bei der Saettigung (Clipping-Grenzen)
Grenze_M = U_Sat * MAX(OilMap_M)
Grenze_L = U_Sat * MAX(OilMap_L)

; =====
; Unkorreliertes Rauschen hinzufuegen
; =====

PRINT, "Kanalrauschen"
PRINT, "Max_H = ", MAX(OilMap_H)
PRINT, "Max_M = ", MAX(OilMap_M)
PRINT, "Max_L = ", MAX(OilMap_L)

Max = MAX(OilMap_H)
OilMap_H = OilMap_H + Max * Alpha_H * ABS(RANDOMN(Seed, Breite, Laenge))      ; Seed wird automatisch

Max = MAX(OilMap_M)
OilMap_M = OilMap_M + Max * Alpha_M * ABS(RANDOMN(Seed, Breite, Laenge))      ; erzeugt und geaendert

Max = MAX(OilMap_L)
OilMap_L = OilMap_L + Max * Alpha_L * ABS(RANDOMN(Seed, Breite, Laenge))

; =====
; Korrelierte Spikes hinzufuegen
; =====

PRINT, "Systemweite Spikes & Ausreisser"
PRINT, "Max_H = ", MAX(OilMap_H)
PRINT, "Max_M = ", MAX(OilMap_M)
PRINT, "Max_L = ", MAX(OilMap_L)

Max = MAX(OilMap_H)
M = MAX(OilMap_M)
IF (M > Max) THEN Max = M
M = MAX(OilMap_L)
IF (M > Max) THEN Max = M

Spike = Max * (1 + D_Sp)
n = 0
FirstSpikeX = -1
FirstSpikeY = -1
FOR x=0,Breite-1 DO BEGIN
  FOR y=0,Laenge-1 DO BEGIN
    n = n + 1
    IF (0 EQ (n MOD N_Sp)) THEN BEGIN      ; Spikes
      OilMap_H(x,y) = Spike
      OilMap_M(x,y) = Spike
      OilMap_L(x,y) = Spike
      PRINT, FORMAT = "(A,$)", "S"
      IF (-1 EQ FirstSpikeX) THEN BEGIN
        FirstSpikeX = x
        FirstSpikeY = y
        PRINT, ""
        PRINT, "FirstSpikeX = (", FirstSpikeX, FirstSpikeY, ")"
      ENDIF
    ENDIF
    IF (0 EQ (n MOD N_A)) THEN BEGIN      ; Ausreisser
      Kanal = ROUND(RANDOMU(Seed) * 3)
      IF (ROUND(RANDOMU(Seed) * 2) > 1.0) THEN BEGIN
        Faktor = 1 + RANDOMN(Seed) * D_A
      ENDIF ELSE BEGIN
        Faktor = 1 - RANDOMN(Seed) * D_A
      ENDELSE
      IF (0 EQ Kanal) THEN OilMap_H(x,y) = ABS(OilMap_H(x,y) * Faktor)
      IF (1 EQ Kanal) THEN OilMap_M(x,y) = ABS(OilMap_M(x,y) * Faktor)
      IF (2 EQ Kanal) THEN OilMap_L(x,y) = ABS(OilMap_L(x,y) * Faktor)
      PRINT, FORMAT = "(A,$)", "A"
    ENDIF
  ENDFOR
ENDFOR
PRINT, ""

; -----
; Falls das Einstreuen von Spikes zur Zeit abgeschaltet sein sollte,
; moechte man trotzdem die Attraktoren an irgendeiner Stelle beobachten.
; Die Position (8,170) ist dabei im Prinzip willkuerlich festgelegt.
; -----
IF (-1 EQ FirstSpikeX) THEN FirstSpikeX=8
IF (-1 EQ FirstSpikeY) THEN FirstSpikeY=170

; =====
; Saettigung
; =====

```

```

PRINT, "Saettigung"
OilMap_H(WHERE (OilMap_H GT Grenze_H)) = Grenze_H
OilMap_M(WHERE (OilMap_M GT Grenze_M)) = Grenze_M
OilMap_L(WHERE (OilMap_L GT Grenze_L)) = Grenze_L

; =====
; Datensaeetze nach der Stoerungskette
; =====

PRINT, "Datensatz nach der Stoerungskette:"
Dif = OilMap_H - OilMap
PRINT, " MSE = ", TOTAL(Dif * Dif) / Laenge / Breite
PRINT, " Vin = ", TOTAL(OilMap)
PRINT, " Vout= ", TOTAL(OilMap_H)
PRINT, " Volumenfehler: ", TOTAL(OilMap_H) / TOTAL(OilMap)

;;PRINT, "*" Antenne H"
;;SHADE_SURF, OilMap, /NOERASE, /T3D, $
;; TITLE="Daten der Antenne H!Cvor der Stoerungskette!C", $
;; XTITLE="<-- Quer zur Flugrichtung -->", $
;; YTITLE="Laengs in Flugrichtung ---->", $
;; ZTITLE="'Dicke" des Oels --->'

;-----

; #####
; Hier beginnt die eigentliche Simulations des INFs
; #####

NeuralNetB = DBLARR(Breite, Laenge) ; INF in dem gerechnet wird (Simulationsvariable)
Attr=DBLARR(500) ; Hier kann man die Attraktoren zum ersten Peak verfolgen
LoopResults = DBLARR(MaxLoops, MaxIterations) ; Hier werden die Ergebnisse der Parameterstudie abgelegt

FOR LoopParameter=1,MaxLoops-1 DO BEGIN
  RadiusG = LoopParameter ; In jedem Durchlauf einen neuen Parameterwert waehlen

  ; -----
  ; Init der Nachbarschafts-WW-Funktion
  ; -----

  Size = 2*RadiusG+1 ; So gross ist der Wirkungsradius von G
  G = DBLARR(Size, Size)
  SigmaDwnG = RadiusG / SQRT(ALOG(100))
  SigmaUpG = SigmaDwnG / 2
  TeilExpUp = 1 / (-2 * SigmaUpG * SigmaUpG)
  TeilExpDwn = 1 / (-2 * SigmaDwnG * SigmaDwnG)
  NormUpG = 1 / (SQRT(2 * !PI) * SigmaUpG)
  NormDwnG = 1 / (SQRT(2 * !PI) * SigmaDwnG)

  EckenAbstand = SQRT(RadiusG^2 + RadiusG^2)
  FOR y=-RadiusG, RadiusG DO BEGIN
    yy = y * y
    FOR x=-RadiusG, RadiusG DO BEGIN
      xx = x * x
      Rquad = xx + yy
      G(x+RadiusG, y+RadiusG) = COS(SQRT(Rquad) * !PI / EckenAbstand) + 1
    ENDFOR
  PRINT, FORMAT = "(A,$)", " ."
  ENDFOR
  G = G / TOTAL(G)
  PRINT, "Max G=", MAX(G), " Min G=", MIN(G)
  PRINT, "Total G=", TOTAL(G)
  Zero = DBLARR(Size, Size)
  Z = Zero

  ; -----
  ; Init des INFs mit dem Startwerten
  ; -----

  PRINT, "NeuralNetA mit den Mittelwerten der Sensoren initialisieren"
  NeuralNetA = (OilMap_H + OilMap_M + OilMap_L) / 3
  MaxDickeInit = MAX(NeuralNetA)

  IF (1 EQ LoopParameter) THEN SHADE_SURF, NeuralNetA ; Nur beim ersten Mal das Startfeld anzeigen

  FOR iterations=0,MaxIterations DO BEGIN
    ; -----
    ; Zunaechst der Hauptterm mit der Sensorcharakteristik
    ; -----
    SumDelta = 0.0
    SumNachb = 0.0
    distfeld = OilMap_H - NeuralNetA
    efeld = distfeld / SigmaA
    dm_H = EtaA * distfeld * EXP(- efeld * efeld / 2)
    distfeld = OilMap_M - NeuralNetA
    efeld = distfeld / SigmaA
    dm_M = EtaA * distfeld * EXP(- efeld * efeld / 2)
    distfeld = OilMap_L - NeuralNetA
    efeld = distfeld / SigmaA
    dm_L = EtaA * distfeld * EXP(- efeld * efeld / 2)

```

```

dmfeld = dm_H + dm_M + dm_L
FOR y=0,Laenge-1 DO BEGIN
  FOR x=0,Breite-1 DO BEGIN
    dm = dmfeld(x,y)
    ;-----
    ; Nun der Nachbarschaftsterm
    ;
    ; Als erstes isoliert man die Nachbarschaftszone aus dem
    ; NeuralNetA. Das muss auch am Rand funktionieren!
    ;-----
    Z = Zero
    px = 0
    py = 0
    bx = RadiusG*2
    by = RadiusG*2
    xa = x - RadiusG
    xe = x + RadiusG
    ya = y - RadiusG
    ye = y + RadiusG
    IF (xa LT 0) THEN BEGIN
      px = -xa
      bx = bx - px
      xa = 0
    ENDIF
    IF (ya LT 0) THEN BEGIN
      py = -ya
      by = by - py
      ya = 0
    ENDIF
    IF (xe GE Breite) THEN BEGIN
      bx = bx - (xe - Breite) - 1
      xe = Breite - 1
    ENDIF
    IF (ye GE Laenge) THEN BEGIN
      by = by - (ye - Laenge) - 1
      ye = Laenge - 1
    ENDIF
    Z(px:px+bx,py:py+by) = NeuralNetA(xa:xe, ya:ye)

    ; -----
    ; Differenzen der Nachbar-Messwerte zum aktuellen Messwert-Punkt bestimmen
    ; -----
    A = Z - NeuralNetA(x,y)
    Richtungsfeld = G * A * EXP(-A*A/(2*SigmaN*SigmaN))

    Beitrag = EtaN * TOTAL(Richtungsfeld)
    IF (Beitrag GT 500) THEN BEGIN
      PRINT, "MAX(NeuralNetA) = ", MAX(NeuralNetA)
      PRINT, "MAX(Richtungsfeld)= ", MAX(Richtungsfeld)
      PRINT, "Beitrag = ", Beitrag
      PRINT, "dm = ", dm
    ENDIF

    IF (x EQ FirstSpikeX) AND (y EQ FirstSpikeY) THEN BEGIN
      ; =====
      ; Hier werden die Attraktoren an einem einzelnen Messpunkt beobachtet (Attraktordiagramm)
      ; =====
      Size = RadiusG * 2 + 1
      A = DBLARR(Size*Size+Size + 4)
      Attr(0:*) = 0.0
      A(0) = (NeuralNetA(x,y))
      A(1) = (OilMap_H(x,y))
      A(2) = (OilMap_M(x,y))
      A(3) = (OilMap_L(x,y))

      p = 4
      FOR xxx=0, Size-1 DO BEGIN
        FOR yyy=0, Size-1 DO BEGIN
          A(p) = (Z(xxx,yyy))
          p = p + 1
        ENDFOR
      ENDFOR

      WSET, 2
      xmin = (MIN(A(0:p))) - 0.1
      xmax = (MAX(A(0:p))) + 0.1
      ymax = 1.1
      PLOT, Attr(400:401), /YNOZERO, $ ; Das macht nur das Fenster auf
      XSTYLE=1, YSTYLE=1, $
      XRANGE={xmin, xmax}, $
      YRANGE={0, ymax}, $
      THICK=1

      p = 4
      Skalierung = 0.45 / MAX( ABS(Richtungsfeld) )
      FOR xxx=0, Size-1 DO BEGIN
        FOR yyy=0, Size-1 DO BEGIN
          PLOTS, [A(p), A(p)], [0, ymax], [0, ABS(Richtungsfeld(xxx,yyy)) * Skalierung], THICK=1
          p = p + 1
        ENDFOR
      ENDFOR

      PLOTS, [A(0), A(0)], [0, ymax], THICK=3
      PLOTS, [A(1), A(1)], [0, ymax*0.75], THICK=2
    ENDIF
  ENDIF
ENDFOR

```

```

PLOTS, [A(2), A(2)], [0, ymax*0.75], THICK=2
PLOTS, [A(3), A(3)], [0, ymax*0.75], THICK=2

XYOUTS, 20, 0.8, "Radius rN =", CHAR.SIZE=2.0
XYOUTS, 40, 0.8, "RadiusG, CHAR.SIZE=2.0

exponent = ( FINDGEN(xmax-xmin+1) - A(0) ) / SigmaA ; Reichweiten-Charakteristik der Antennen
OPLOT, EXP( - exponent ^ 2 / 2 ), LINESSTYLE=1
exponent = ( FINDGEN(xmax-xmin+1) - A(0) ) / SigmaN ; Reichweiten-Charakteristik der Nachbarn
OPLOT, EXP( - exponent ^ 2 / 2 ), LINESSTYLE=2
WSET, 0
ENDIF

; -----
; Das Resultat wird schliesslich abgespeichert (mit Clipping)
; -----
SumDelta = SumDelta + dm * dm
SumNachb = SumNachb + Beitrag * Beitrag
dm = dm + Beitrag
Wert = NeuralNetA(x,y) + dm / tau
IF (Wert LT 0.0) THEN Wert=0.0
NeuralNetB(x,y) = Wert
ENDFOR
PRINT, FORMAT = "(A,$)", "."
ENDIF
NeuralNetA = NeuralNetB
WSET, 0
SHADE_SURF, NeuralNetA, $
XTITLE="<-- Quer zur Flugrichtung -->", $
YTITLE="Laengs in Flugrichtung ---->", $
ZTITLE="Dicke" des Oels ---->, $
ZRANGE=[0, MaxDickeInit]
XYOUTS, 50, 180, 'Zustand des INFs', CHAR.SIZE=1.5
PRINT, "
PRINT, "Sie sehen Iteration #", iterations
PRINT, "SumDelta =", SumDelta
PRINT, "SumNachb =", SumNachb
Dif = NeuralNetA - OilMap
EpsMSE(iterations) = TOTAL(Dif * Dif) / Laenge / Breite
EpsV (iterations) = TOTAL(NeuralNetA) / TOTAL(OilMap)
PRINT, " MSE =", EpsMSE(iterations)
PRINT, " Vin =", TOTAL(OilMap)
PRINT, " Vout =", TOTAL(NeuralNetA)
PRINT, " Volumenfehler: ", EpsV(iterations)

; =====
; Kombi-Bild EpsMSE + EpsV anzeigen
; =====
NFaktor=MAX(EpsMSE)/MAX(EpsV) ; Screen-Normierung (EpsV auf EpsMSE normieren)
WSET, 1
PLOT, EpsMSE(0:iterations), /YNOZERO, $
XRANGE=[0, MaxIterations], $
XSTYLE=1, $
XTITLE='Iterationen -->', $
YTITLE='EpsMSE -->'
OPLOT,EpsV(0:iterations) * NFaktor, THICK=2
ENDFOR

LoopResults(LoopParameter-1,*) = EpsMSE(0:MaxIterations-1)
ymin = MIN(LoopResults(0:LoopParameter-1,*))
ymax = MAX(LoopResults(0:LoopParameter-1,*))

WSET, 0
PLOT, LoopResults(0,*), /YNOZERO, XSTYLE=1, YSTYLE=1, LINESSTYLE=0, $
YRANGE=[ymin, ymax], $
XTITLE='Iterationen -->', $
YTITLE='EpsMSE -->'
FOR i=0,MaxLoops-1 DO BEGIN
OPLOT, LoopResults(i,*), LINESSTYLE = (i+1) MOD 6
ENDFOR

PLOTS, [6,8,8.2], [32,37,36.4]
PLOTS, [8,7.3], [37, 36.4]
XYOUTS, 7.5, 34, "EtaN", CHAR.SIZE=1.4

; =====
; Daten sichern
; =====

SAVE, FILENAME=MyOutput, /VERBOSE, OilMap, LoopResults, EpsMSE, EpsV
PLOT, LoopResults(0:LoopParameter,*), /YNOZERO

WAIT, 5

; =====
; Zustandsbild vom INF speichern
; =====

SET_PLOT, 'PS'
DEVICE, BITS_PER_PIXEL=8
DEVICE, /BOLD, FONT_SIZE=16
DEVICE, ENCAPSULATED=1
DEVICE, FILENAME=ZustandEPS

```







```

ACenterX = 0;
for (;;)
{
    if (0==XCheckMaskEvent(MyDisplay, -1, &Report)) continue;
    switch(Report.type)
    {
        case KeyPress:
        {
            KeySym TastenSym;
            char B[256];
            int N;

            N = XLookupString( (XKeyEvent*)&Report, B, 256, &TastenSym, NULL);
            B[N] = 0;
            switch(TastenSym)
                // Achtung: running case...
            {
                case XK_Escape:      goto EXIT;
                case XK_KP_Enter:
                case XK_Return:      Save(); break;
                case XK_space:      Clear(); break;
                case XK_KP_Add:
                case XK_plus:       if (Rauschfaktor<250) Rauschfaktor++; break;
                case XK_KP_Subtract: // Minustaste am Ziffernblock, mit NumLock
                case XK_R4:         // Minustaste am Ziffernblock, ohne NumLock
                case XK_minus:     if (Rauschfaktor> 0) Rauschfaktor--; break;
                default:           printf("Unknown keysym press %x (%s)\n", TastenSym, B); break;
            }
            XClearArea(MyDisplay, MyWindow, Breite+150, 140, 50, 10, FALSE);
            sprintf(B, "%3d.%d %s\n", Rauschfaktor/10, Rauschfaktor%10);
            TEXT(Breite+150, 150, B); // Aktuellen Rauschfaktor anzeigen
            break;
        }
        case MotionNotify:
        {
            XMotionEvent *ME = (XMotionEvent*)&Report;

            if (ME->x >= Breite)
            {
                if (ACenterX) XDrawArc(MyDisplay, MyWindow, MyGC, ACenterX-ARx/2,
                    ACenterY-ARy/2, 2*ARx, 2*ARy, 0, 9999999);

                Draw = FALSE;
                ACenterX = 0;
                break;
            }
            RadiusX = ME->x;
            RadiusY = ME->y;
            break;
        }
        case ButtonPress:
        {
            XButtonEvent *BE = (XButtonEvent*)&Report;
            if (BE->x >= Breite) break; // Nicht ins rechte Teilfenster malen!
            CenterX = RadiusX = BE->x;
            CenterY = RadiusY = BE->y;
            Draw = TRUE;
            break;
        }
        case ButtonRelease:
        {
            AddSpot(ACenterX, ACenterY, ARx, ARy);
            Draw = FALSE;
            ACenterX = 0;
            break;
        }
        default:           printf("Unknown type of report %d\n",Report.type); break;
    }
}
if (Draw)
{
    Rx = ABS(RadiusX - CenterX);
    Ry = ABS(RadiusY - CenterY);

    if (ACenterX) XDrawArc(MyDisplay, MyWindow, MyGC, ACenterX-ARx/2,
        ACenterY-ARy/2, 2*ARx, 2*ARy, 0, 9999999);
    ACenterX = CenterX; ACenterY = CenterY;
    ARadiusX = RadiusX; ARadiusY = RadiusY;
    ARx = Rx; ARy = Ry;
    XDrawArc(MyDisplay, MyWindow, MyGC, CenterX-Rx/2, CenterY-Ry/2,
        2*Rx, 2*Ry, 0, 9999999);
}
}

EXIT:
return(0); // Alles okay, keine Fehler aufgetreten
}

```

## Literatur

- [1] S. Amari: *Dynamics of pattern formation in lateral-inhibition type neural fields*, Biological Cybernetics, Ausgabe 27:77-88, 1977
- [2] A. Steinhage: *Dynamical Systems for the Generation of Navigation Behavior*, Ph. D. thesis, Berichte aus der Physik, Shaker Verlag 1998, ISBN 3-8265-3508-1
- [3] M. Giese: *A Dynamical Model for the Perceptual Organization of Apparent Motion*, Dissertation 1997, Institut für Neuroinformatik, RUB
- [4] J. F. Böhme: *Stochastische Signale*, B. G. Teubner 1993, ISBN 3-519-06160-0
- [5] H. D. Lüke: *Signalübertragung*, 3. Auflage, Springer 1985, ISBN 3-540-15526-0
- [6] N. W. Guinard: *Remote Sensing of oil slicks*, Procs VII.th Sympos. on Remote Sensing of Environment, 1971
- [7] N. W. Guinard: *Remote sensing of ocean effects with radar*, AGARD Conf. Procs no. 90: Propagation limitations in remote sensing, 1971
- [8] A. T. Edgerton, G. Woolever: *Airborne oil pollution surveillance system*, Proc. 9th Intern. Symp. Rem. Env. 1791, Univ. of Michigan, Ann. Arbor, 1974
- [9] J. D. Kraus: *Radio Astronomy*, 1966
- [10] Bronstein: *Taschenbuch der Mathematik*, 24. Auflage, Thun 1989
- [11] U. Tietze, Ch. Schenk: *Halbleiter-Schaltungstechnik*, 9. Auflage, Springer 1991, ISBN 3-540-19475-4
- [12] H. Ritter, Th. Martinetz, K. Schulten: *Neuronale Netze*, 2. Auflage, Addison-Wesley 1991, ISBN 3-89319-131-3

- 
- [13] RSI Research Systems Inc.: *IDL Basics*
- [14] RSI Research Systems Inc.: *IDL User's Guide*
- [15] RSI Research Systems Inc.: *IDL Reference Guide*
- [16] R. M. Haralick: *Automatic Remote Sensor Image Processing*, Topics in Applied Physics, Vol. 11, Springer 1976, ISBN 3-540-07579-8
- [17] Online-Manualpage von SunOS Version 5.6: *drand48(3C)* [Exakte Algorithmus-Beschreibung des verwendeten Zufallszahlengenerators zur numerischen Erzeugung eines weißen Rauschens]
- [18] Richard F. Thompson: *Das Gehirn*, Spektrum-Verlag Heidelberg, 1990, ISBN 3-89330-696-X [Grundlagen der Neurologie]
- [19] A. Takeuchi, S. Amari: *Formation of topographic maps in columnar microstructures in nerve fields*, Biological Cybernetics, Ausgabe 35:63-72, 1979
- [20] H. Unbehauen: *Regelungstechnik I*, 8. Auflage, Vieweg 1994, ISBN 3-528-73332-2
- [21] V. Braitenberg, A. Schütz: *Cortex: hohe Ordnung oder größtmögliches Durcheinander?*, Gehirn und Kognition, Spektrum-Verlag 1992, ISBN 3-922508-55-3
- [22] W. H. Press et al.: *Numerical recipes in C: the art of scientific computing*, Cambridge University Press 1994, ISBN 0-521-43108-5
- [23] C. Winkel: *Untersuchungen zur Rekonstruktion von räumlichen Verteilungen von Strahlungstemperaturen im Mikrowellenbereich mit Hilfe der Maximum-Entropie-Methode*, Diplomarbeit 1993, RUB Institut für HF-Technik
- [24] R. G. Reeves: *Manual of remote sensing*, Vol. I, American Society of photogrammetry, Keuffel & Esser Company 1975.

- 
- [25] A. Steinhage, G. Schöner: *Self-calibration based on invariant view recognition: Dynamic approach to navigation*, Robotics and Autonomous Systems 20/1997, p. 133–156, 1997
- [26] Gerthsen Physik, 19. Auflage, Springer 1997, ISBN 3-540-62988-2
- [27] K. Grüner: *Unterlagen zum Projekt MERES*, DLR (Deutsches Zentrum für Luft- und Raumfahrt) 1992
- [28] Griebel, Grüner, Kahlisch, Schreiber, Witte: *Projektunterlagen zum Projekt MERES (Mehrfrequenzmikrowellenradiometer zur Erkundung der Seeoberfläche)*, DLR 1992
- [29] H. Schreiber: *Schulungsunterlagen zum MERES-Projekt*, DLR 1992
- [30] F. T. Ulaby, R. K. Moore, A. K. Fung: *Microwave Remote Sensing*, Vol. I, Addison–Wesley 1981
- [31] E. Schanda (Editor): *Remote Sensing for Environmental Sciences*, Springer 1976, ISBN 3-540-07465-1
- [32] H. Neven: *Dynamics for vision-guided autonomous mobile robots*, Dissertation 1997, VDI Fortschrittsberichte Reihe 8, Nr. 606, VDI Verlag 1997
- [33] D. Nass: *Wahrnehmung und Sensorfusion für einen mobilen Roboter*, Institut für Neuroinformatik, Diplomarbeit Elektrotechnik RUB 1997
- [34] B. Vowinkel, J. K. Peltonen, W. Reinert, K. Grüner, B. Aumiller: *Airborne Imaging System Using a Cryogenic 90 GHz Receiver*, IEEE Transactions on Microwave Theory and Techniques, Vol. MTT–29, No. 6, June 1981
- [35] B. Vowinkel, K. Grüner, W. Reinert: *Cryogenic all solid-state millimeter-wave receivers for airborne radiometry*, IEEE Transactions on Microwave Theory and Techniques, Vol. MTT–31, No. 12, December 1983

- 
- [36] K. Grüner, H. Öttl, H. Süß: *Fernerkundung mit Mikrowellen- und Millimeterwellen-Radiometern*, DLR-Nachrichten Heft 58, November 1989
- [37] H. Smid, R. Reuter, K. Grüner: *Luftüberwachungssystem zur Erkennung von Meeresverschmutzungen*, Informationsschrift des Bundesministeriums für Verkehr, Abteilung Wasserstraßen, Stand Mai 1991
- [38] *Luftüberwachungssystem zur Erkennung von Meeresverschmutzungen*, Informationsschrift des Bundesministeriums für Verkehr, Abteilung Wasserstraßen, Stand Januar 1998

## Abbildungsverzeichnis

1	Ansicht des Antennengehäuses von außen. . . . .	4
2	Antennenbilder (Simulation). Verwendeter Parametersatz: $r_H = 3; r_M = 7,5; r_L = 15; A_H = A_M = A_L = 0;$ $\alpha_H = \alpha_M = \alpha_L = 5\%; N_{Sp} = 1771; D_{Sp} = 50\%; N_A = 562;$ $D_A = 20\%; U_{Sat} = 90\%.$ . . . . .	7
3	Antennenbilder (Reale Daten) . . . . .	7
4	Atmosphärische Absorptionsspektren für $O_2$ und $H_2O$ . . . . .	8
5	Atmosphärische Fenster im Frequenzspektrum . . . . .	10
6	Der 10%-Rand einer Gaußverteilung . . . . .	12
7	Hardcopy von Synth . . . . .	14
8	Ölverteilung, Typ $D_1$ . . . . .	16
9	Ölverteilung, Typ $D_2$ . . . . .	16
10	Ölverteilung, Typ $D_3$ . . . . .	17
11	Ölverteilung, Typ $D_4$ . . . . .	17
12	Simulation einer einfachen Meßkette . . . . .	18
13	Scanline . . . . .	21
14	Simulierte Ölverteilung (ohne Störungen, vor der Abtastung). Verwendeter Parametersatz: $r_H = 3; r_M = 7,5; r_L = 15; A_H =$ $A_M = A_L = 0; \alpha_H = \alpha_M = \alpha_L = 5\%; N_{Sp} = 1771; D_{Sp} = 50\%;$ $N_A = 562; D_A = 20\%; U_{Sat} = 90\%.$ . . . . .	23
15	Offsetverschiebung . . . . .	25
16	Meßwert $m(t)$ mit Spikes . . . . .	27
17	Ausreißer . . . . .	27
18	Struktur der Störungskette . . . . .	30

19	Zweidimensionale Feldstruktur . . . . .	33
20	Gewichtungen . . . . .	36
21	Projektion der Datenpunkte auf das Neuronale Feld . . . . .	38
22	Neuronen auf ihren festen Gitterplätzen . . . . .	40
23	INF im angeregten Zustand . . . . .	40
24	Ein einzelnes Neuron empfängt seine Reize von (vielen) Sensoren <i>und</i> seinen Nachbarn . . . . .	41
25	Auswirkung der Störungskette. Verwendeter Parametersatz: $R_H = 1, 0; A_H = 0, 0; \alpha_H = 3\%; N_{Sp} = 1771; D_{Sp} = 50\%; N_A = 562; D_A = 20\%; U_{sat} = 90\%$ . . . . .	42
26	Meßwerte und Attraktoren . . . . .	46
27	Reichweiten der Attraktoren . . . . .	48
28	Phasendiagramm zur Bildung von Attraktoren aus mehreren Einzelkomponenten . . . . .	48
29	Simulierte Eingangsverteilung ohne Störungen . . . . .	51
30	Eingangsdaten mit Störungen. Links der H-Kanal mit 20% Rauschen, daneben die M- und L-Kanäle mit je 1% Rauschen. . . . .	51
31	Meßdaten auf der Eingangsseite . . . . .	52
32	Wirkung von <b>I.1</b> auf die Meßdaten . . . . .	52
33	Meßwerte und Attraktoren . . . . .	53
34	Zur Wahl der $\vartheta_i$ bei drei unterschiedlichen Sensoren. . . . .	55
35	Eine Datenzeile . . . . .	57
36	Definition von $r_N$ . . . . .	58
37	Mögliche Nachbarschaftsgewichtungen . . . . .	59
38	Simulierte Eingangsverteilung ohne Störungen . . . . .	65

39	Eingangsdaten mit Störungen. Links der H-Kanal mit 20% Rauschen, daneben die M- und L-Kanäle mit je 3% Rauschen.	65
40	Startwerte mit 20 % Rauschen auf dem H-Kanal und nur 3 % Rauschen auf den anderen Kanälen: $\epsilon_{MSE} = 757,71$ und $\epsilon_V = 2,201$ .	66
41	Zur Wirkung von <b>I.2</b> . Parameter: $r_N = 5, \eta_A = 1, \eta_N = 2, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 20\%, \alpha_M = 3\%, \alpha_L = 3\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%$	66
42	Darstellung der Nachbarschafts-Cosinusgewichtung	67
43	Schnitt durch die Nachbarschafts-Cosinusgewichtung	67
44	Spike-Attraktordiagramm. Gegenüber den vorangegangenen 3D-Darstellungen sind hier die Dickenwerte auf der horizontalen Achse dargestellt. Auf der vertikalen Achse ist die Wechselwirkungsstärke aufgetragen.	68
45	Spike-Attraktoren im Endzustand	72
46	Zum Zeitskalenfaktor $\tau$	76
47	$\sigma_N$ im Attraktorendiagramm (gestrichelte Kurve)	77
48	Einfluß des Nachbarschaftsparameters $\sigma_N$ auf das Fehlermaß $\epsilon_{MSE}$	78
49	Wirkung von $2\sigma_N^2 = 5$ auf Attraktorbild und INF. Parameter: $r_N = 5, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \tau = 10$	79
50	Wirkung von $2\sigma_N^2 = 10$ auf Attraktorbild und INF. Parameter: $r_N = 5, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \tau = 10$	79

- 51 Wirkung von  $2\sigma_N^2 = 30$  auf Attraktorbild und INF. Parameter:  
 $r_N = 5, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H =$   
 $A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771,$   
 $D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \tau = 10 \dots$  79
- 52 Wirkung von  $2\sigma_N^2 = 40$  auf Attraktorbild und INF. Parameter:  
 $r_N = 5, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H =$   
 $A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771,$   
 $D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \tau = 10 \dots$  80
- 53 Wirkung von  $2\sigma_N^2 = 100$  auf Attraktorbild und INF. Parameter:  
 $r_N = 5, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H =$   
 $A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771,$   
 $D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \tau = 10 \dots$  80
- 54 Kurvenschar zum Verhältnis  $\eta_A : \eta_N$ . Parameter:  $r_N = 5, \eta_A =$   
 $18 \dots 0, \eta_N = 1 \dots 19, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M =$   
 $A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} =$   
 $50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28$  83
- 55 Fehlermaß  $\epsilon_{MSE}$  zur vorangegangenen Abbildung nach je 100  
 Iterationen  $\dots \dots \dots$  84
- 56 Zum Verhältnis  $\eta_A \gg \eta_N$ . Parameter:  $r_N = 5, \eta_A = 18, \eta_N = 1,$   
 $R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%,$   
 $\alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562,$   
 $D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28 \dots \dots \dots$  85
- 57 Zum Verhältnis  $\eta_A \ll \eta_N$ . Parameter:  $r_N = 5, \eta_A = 0, \eta_N = 19,$   
 $R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%,$   
 $\alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562,$   
 $D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28 \dots \dots \dots$  85

- 58 Zum Einfluß der Startwerte. Parameter:  $r_N = 5$ , Startwerte aller  $m(\vec{r}) := 116, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28 \dots 88$
- 59 Zum Einfluß der Startwerte. Parameter:  $r_N = 5$ , Startwerte aller  $m(\vec{r}) := 116, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28 \dots 88$
- 60 Einfluß Startwerte und Verifikation der Simulation. Parameter:  $r_N = 5$ , Startwerte aller  $m(\vec{r}) := 116, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28 \dots 89$
- 61 Einfluß der Startwerte auf  $\epsilon_{MSE}$ . Parameter:  $r_N = 5$ , Startwerte aller  $m(\vec{r}) := 116, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 50, \tau = 28 \dots 90$
- 62 Kurvenschar zum Radius  $r_N$ . Parameter:  $r_N = 5, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 40, \tau = 28 \dots 92$
- 63 Optimalkurve zum Radius  $r_N$ . Parameter:  $r_N = 0 \dots 15, \eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2,5, R_L = 5, A_H = A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 40, \tau = 28 \dots 93$

64	INF bei verschiedenen $r_N$ nach je 100 Iterationen. Parameter: $\eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2, 5, R_L = 5, A_H = A_M = A_L = 0,$ $\alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%,$ $N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 40, \tau = 28 \dots$	95
65	INF bei verschiedenen $r_N$ nach je 100 Iterationen. Parameter: $\eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2, 5, R_L = 5, A_H = A_M = A_L = 0,$ $\alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771, D_{Sp} = 50\%,$ $N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 40, \tau = 28 \dots$	95
66	Fehlerverläufe bei verschiedenen $r_N$ nach je 100 Iterationen. Parameter: $\eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2, 5, R_L = 5, A_H =$ $A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771,$ $D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 40,$ $\tau = 28 \dots$	96
67	Attraktorbilder bei verschiedenen $r_N$ nach je 100 Iterationen. Parameter: $\eta_A = 1, \eta_N = 10, R_H = 1, R_M = 2, 5, R_L = 5, A_H =$ $A_M = A_L = 0, \alpha_H = 10\%, \alpha_M = 10\%, \alpha_L = 10\%, N_{Sp} = 1771,$ $D_{Sp} = 50\%, N_A = 562, D_A = 20\%, U_{sat} = 90\%, \sigma_A = 20, \sigma_N = 40,$ $\tau = 28 \dots$	96
68	Geplante Meßdatenverarbeitung	98
69	Meßprinzip (aus [24])	100
70	Scherungseffekt infolge der Eigenbewegung des Flugzeugs	101
71	Aufbau der Meßapparatur	102
72	Strahlungstemperaturen über dem Einfallswinkel für verschie- dene Öldicken	105
73	Reale Meßdaten, H-Kanal (89 GHz), 600 Scanlines. Im hintere- ren Bereich die ölverschmutzte Zone, vorn in der Mitte das Si- gnal eines Schiffes.	107

---

74	UV-Kamerabild des Meßgebietes; links der Ölfleck, rechts das Schiff. . . . .	107
75	Reale Meßdaten, oben: H-Kanal (vordere und hintere 89 GHz-Meßgruppe), unten: Aufsicht auf das Meßgebiet . . . . .	108
76	Aufgeteilte Meßdaten des H-Kanals; links von der vorderen Antenne, rechts von der hinteren Antenne . . . . .	109
77	Aufgeteilte Meßdaten des H-Kanals nach der Offset-Korrektur; links von der vorderen Antenne, rechts von der hinteren Antenne . . . . .	109
78	Alternierend zusammengefügte Daten beider Meßgruppen. Die Meßwerte zu dieser Kurve werden später als Signal der H-Antenne betrachtet. . . . .	110
79	Zur winkelabhängigen Offsetkorrektur. Links: Summe über die Meßwerte der einzelnen Scanlines, rechts: mittlere Meßwerte pro Scanspalte im Kalibrierbereich (Zeilen 200 bis 400). . . . .	111
80	Meßdaten des L-Kanals nach der Vorverarbeitung. . . . .	113
81	Wirkung der Offsetkorrektur auf die Meßdaten der H- (oben), M- (mittig) und L-Kanäle. Auf der linken Seite sind jeweils die Eingangdaten dargestellt, auf der rechten Seite die Ausgangsdaten der Vorverarbeitung. . . . .	114
82	Startwerte des INFs . . . . .	115
83	Zustand des INFs nach der ersten Iteration. Die Höhenlinien haben einen Abstand von je 100 Intensitätsstufen. . . . .	116
84	Zustand des INFs nach der zweiten Iteration . . . . .	117
85	Zustand des INFs nach der dritten Iteration . . . . .	117
86	Zustand des INFs nach der fünften Iteration . . . . .	118

---

87	Links: Zustand des INFs nach 20 Iterationen. Rechts: Entwicklung des Integrals über alle Meßwerte . . . . .	119
88	Theoretisch erwarteter Kurvenverlauf für die Helligkeitstemperaturzunahme in Abhängigkeit von der Öldicke . . . . .	121
89	Meßwerte und Attraktoren . . . . .	122
90	Mehrfache Attraktoren pro Meßwert . . . . .	122
91	Darstellung der geplanten Meßkette . . . . .	130
92	Elektrischer Aufbau der Meßkanäle (aus [28]) . . . . .	133
93	Bildschirm–Hardcopy des erstellten Softwaresystems . . . . .	134

**Tabellenverzeichnis**

1	Datenformat der Ausgabe von Synth . . . . .	14
2	Verhältnisse der Antennenradien . . . . .	21
3	Parameter der Störungskette . . . . .	29
4	Auswirkung verschiedener Gewichtungen . . . . .	36
5	Anzahl Nachbarn . . . . .	94
6	Gewählte Parameter für die realen Meßdaten . . . . .	116