

Teilchenrekonstruktion bei staubigen Plasmen mittels neuronalen Netzen

Bachelorarbeit im Fach Physik

eingereicht am Institut für Physik der Universität Greifswald

am 25. März 2022

von Oliver Wolf

Erstgutachter: Prof. Dr. André Melzer
Zweitgutachter: Prof. Dr. Ralf Schneider

Inhaltsverzeichnis

1	Einleitung	2
2	Theoretische Grundlagen	3
2.1	Das Plasma	3
2.2	Staubige Plasmen	5
2.2.1	Aufladung der Staubpartikel	5
2.3	Kräfte im staubigen Plasma	8
2.3.1	Gravitationskraft	8
2.3.2	Elektrische Feldkraft	8
2.3.3	Thermophorese	8
2.3.4	Neutralgasreibung	9
2.3.5	Ionenwind	9
2.3.6	Gesamtheit der Kräfte	10
2.4	Neuronale Netze	11
2.4.1	Datenverarbeitung	11
2.4.2	Lernprozess	12
3	Messaufbau und Durchführung	14
3.1	Aufbau	14
3.2	Messungen	15
3.3	Auswertung der Messdaten	15
3.4	Aufbau des neuronalen Netzes	16
3.5	Trainingsdaten und Trainingsablauf	17
4	Auswertungen mit der ersten Messung	18
4.1	Generierung der Trainingssets	18
4.2	Berechnung der initial fields mittels der 4. Wurzel	19
4.3	Berechnung der initial fields mittels des Durchschnitts	29
4.4	Durchschnitt der beiden bisherigen initial fields als neues initial field	35
5	Auswertung der zweiten Messung	39
5.1	Erstellung der Trainingssets	39
5.2	Training mit größeren Intensitätsverteilungen im training field	40
5.3	Training bei Reduzierter Größe der Partikel im training field	43
6	Zusammenfassung	47
	Literaturverzeichnis	49

1 Einleitung

Die Plasmaphysik ist heutzutage ein wichtiges Teilgebiet der Physik. Plasmen werden in vielen Bereichen wie der Textilindustrie zum Bearbeiten von Oberflächen bis hin zur Beleuchtung von Räumen durch Plasmalampen verwendet. In der Natur kommen Plasmen in Form von Blitzen oder Polarlichter vor. Auch im Weltall sind sie beispielsweise in Sonnenwinden und in Gasriesen wie dem Jupiter zu finden [1, 2]. Neben Elektronen, Ionen und Neutralgasatomen enthalten diese Plasmen aber noch kleine Festkörperpartikel, weshalb sie als staubige Plasmen bezeichnet werden. Durch das häufige Auftreten staubiger Plasmen im Weltall hat die Untersuchung von ihnen immer mehr an Bedeutung gewonnen. Im Labor werden staubige Plasmen durch Zugabe von kleinen, runden Festkörpern mit einem Durchmesser von einigen Nanometern bis hin zu wenigen Mikrometern gezielt erzeugt.

Um die Phänomene in staubigen Plasmen genauer untersuchen zu können, ist die Ortung der Staubteilchen von großer Bedeutung. Dementsprechend wurden verschiedene Methodiken entwickelt, um die Teilchen im zwei- als auch im dreidimensionalen Raum zu orten [3, 4]. Als mit am besten hat sich der „Shake-The-Box“-Algorithmus erwiesen [5, 6]. Je mehr Staubteilchen der Algorithmus verarbeiten muss, desto mehr Zeit nimmt er in Anspruch. Eine mögliche Alternative bietet maschinelles Lernen. Es wurden bereits verschiedene Algorithmen für zweidimensionale Auswertungen von Bildern entwickelt [7, 8]. Sie sind besonders für die Analyse von binären staubigen Plasmen, also Plasmen, denen zwei verschiedene Arten von Staubpartikeln zugegeben werden, die sich meist in der Größe unterscheiden, oder zur Analyse von Wellen in Staubwolken geeignet. Deep Learning hat sich dabei als sehr vielversprechende Methodik erwiesen Objekte auf Bildern zu erkennen [9]. Neuronale Netze gewinnen in der heutigen Zeit in immer mehr Bereichen an Bedeutung, da sie sehr flexibel und einfach gestaltet werden können.

In dieser Arbeit beschäftige ich mich mit einem Convolutional Neural Network, welches bereits von A. Melzer *et al.* bei einem anderen Messaufbau untersucht wurde [10]. Ich möchte mich hier jedoch auf die Untersuchung der Stabilität des Trainings konzentrieren. Mit der Zeit ist das Einsatzgebiet von künstlichen Neuronalen Netzen immer weiter gewachsen und ihre Aufgaben wurden immer komplexer. Dadurch wurden die Netze auch immer größer und das Problem, dass das Training nicht komplett verstanden werden kann, wurde immer deutlicher. Zwar ist das später zur Auswertung genutzte Netzwerk nicht besonders groß, dennoch kann man es bereits als „Black-Box“ betrachten. Um neuronale Netze zuverlässig anwenden zu können, ist kein vollständiges Verständnis ihrer Lernentscheidungen notwendig. Durch Variation einiger Parameter möchte ich testen, wie das Netzwerk auf Änderungen reagiert und wie das die Stabilität des Trainings beeinflusst. Die Beurteilung der Qualität des Netzwerkes ist dabei nur zweitrangig.

2 Theoretische Grundlagen

2.1 Das Plasma

Ein physikalisches Plasma beschreibt ein vollständig oder teilweise ionisiertes Gas. Daher sind in einem Plasma nicht nur Neutralgasatome, sondern auch frei bewegliche Elektronen und Ionen vorhanden. Die Ladungen der Elektronen und der Ionen gleichen sich auf das gesamte Plasma gesehen ganz oder fast vollständig aus, weshalb man es auch als quasineutral bezeichnet. Dabei gilt nach [11]:

$$\left| \sum_j Z_j e n_{i0,j} - n_{e0} e \right| \ll n_{e0} e \quad , \quad (1)$$

worin j die verschiedenen Arten der Ionen mit Z_j -facher Elementarladung e sind. Die Parameter $n_{i0,j}$ und n_{e0} stehen für die jeweiligen Teilchenzahldichten der Ionen bzw. Elektronen. In unseren Plasmen mit Argongas sind primär einfach geladene Ionen vorhanden, weshalb man $n_{i0} \approx n_{e0}$ annehmen kann. Durch die freien Ladungsträger hat ein Plasma viele Eigenschaften, die es von einem normales Gas unterscheiden. So besitzt es eine sehr gute elektrische Leitfähigkeit und kann zusätzlich eingebrachte Ladungsträger gut abschirmen. Diesen Abschirmungseffekt kann man sich gut mit Hilfe einer Probeladung Q betrachten, die sich in einem homogenen Plasma befindet, welches nur aus Elektronen und einfach geladenen Ionen besteht. In diesem Fall ergibt sich aus der Maxwell-Gleichung

$$\vec{\nabla} \vec{E} = \frac{\rho}{\varepsilon_0} \quad (2)$$

mit ρ als Ladungsdichte und ε_0 als Dielektrizitätskonstante die elektrostatische Laplace-Gleichung in leicht abgewandelter Form

$$- \varepsilon_0 \Delta \Phi = e(n_i - n_e) \quad . \quad (3)$$

Darin ist Φ das elektrische Potential des Plasmas. Für die Teilchendichten n_e und n_i kann man Boltzmanverteilungen annehmen, weshalb sie wie folgt beschrieben werden können:

$$n_{i,e} = n_{i,e0} \exp\left(\frac{\pm e \Phi(r)}{k_B T_{i,e}}\right) \quad . \quad (4)$$

Zu sehen ist die Abhängigkeit der Teilchendichten von der Gesamtteilchendichte $n_{i,e0}$ und der Temperatur $T_{i,e}$. Auch wenn durch die Quasineutralität $n_{e0} \approx n_{i0}$ gilt, so unterscheiden sich Elektronen und Ionen dennoch in der Temperatur. Elektronen bewegen sich in initiierten Plasmen auf der Erde deutlich schneller als die schwereren Ionen, weshalb ihre Temperatur auch höher ist. Nähert man die Verteilungen mit

der ersten Ordnung der Taylor-Entwicklung, so erhält man unter Berücksichtigung der Quasineutralität und Gl. (3)

$$\nabla^2 \Phi = \left(\frac{1}{\lambda_{D,e}^2} + \frac{1}{\lambda_{D,i}^2} \right) \Phi = \frac{1}{\lambda_D^2} \Phi \quad . \quad (5)$$

Die Größen $\lambda_{D,e}$ und $\lambda_{D,i}$ sind die Debyelängen für die Elektronen und die Ionen und sind wie folgt definiert:

$$\lambda_{D,e} = \sqrt{\frac{\varepsilon_0 k_B T_e}{n_{e0} e^2}} \quad \text{und} \quad \lambda_{D,i} = \sqrt{\frac{\varepsilon_0 k_B T_e}{n_{i0} e^2}} \quad . \quad (6)$$

Diese Größen geben den Abstand an, bei dem das Potential auf einen Anteil von $1/e$ abgefallen ist. Die mittlere Debyelänge $\lambda_{D,e}$ berechnet sich aus

$$\frac{1}{\lambda_D^2} = \frac{1}{\lambda_{D,e}^2} + \frac{1}{\lambda_{D,i}^2} \quad . \quad (7)$$

In Kugelkoordinaten ergibt sich als Lösung von Gl. (5) das Debye-Hückel-Potential oder auch Yukawa-Potential

$$\Phi(r) = \frac{Q}{4\pi\varepsilon_0 r^2} e^{-r/\lambda_D} \quad . \quad (8)$$

Für kleine Abstände r von der Probeladung Q ist das Potential dem Culombpotential sehr ähnlich. Bis zu einem Radius $r = \lambda_D$ ist die Quasineutralität also verletzt. Darüber hinaus ist das Potential bereits sehr stark abgeschwächt. Ein wichtiger Parameter zur Charakterisierung eines Plasmas ist dabei die Anzahl von Teilchen, die sich mit maximal einer Debyelänge Abstand um die Probeladung befinden. Dieser Bereich heißt Debye-Kugel und die Anzahl der Teilchen in diesem Bereich lässt sich durch

$$N_D = \frac{4}{3}\pi\lambda_D^3 n \quad (9)$$

berechnen. Plasmen mit vielen Teilchen $N_D \gg 1$ in der Debye-Kugel werden als ideal bezeichnet, weil mehr Teilchen die Abschirmung der Probeladung verstärken. Hingegen sind Plasmen mit $N_D \ll 1$ stark gekoppelt bzw. nicht ideal, da kaum Abschirmungseffekte auftreten. Je geringer die Abschirmung, desto stärker ist die Wechselwirkung mit den benachbarten Teilchen. Wie stark diese Kopplung der Nachbarpartikel ist, gibt der Kopplungsparameter Γ an:

$$\Gamma = \frac{Q^2}{4\pi\varepsilon_0 b k_B T} \quad . \quad (10)$$

Der Parameter b ist dabei der Wigner-Seitz-Radius

$$b = \left(\frac{3}{4\pi n} \right)^{\frac{1}{3}}, \quad (11)$$

welcher ein Maß für den Teilchenabstand ist. Je kleiner der Kopplungsparameter, desto stärker ist die Abschirmung. Daher gelten Plasmen mit $\Gamma \ll 1$ als ideal, während Plasmen mit einem Kopplungsparameter $\Gamma \gg 1$ als stark gekoppelt gelten. Laborplasmen, die nur aus Ionen, Elektronen und Neutralgas bestehen, sind in der Regel schwach gekoppelt. Fügt man dem Plasma Staub hinzu, so nimmt dieser viele Ladungsträger auf, was die Abschirmung schwächt und zu stark gekoppelten Plasmen führt. Ab einem kritischen Kopplungsparameter Γ_c ist die Kopplung unter den Staubteilchen so groß, dass sie sich wie in einem Gitter anordnen und nur noch an der Stelle schwingen.

2.2 Staubige Plasmen

Als staubige oder auch kolloidale Plasmen bezeichnet man Plasmen, die neben den typischen Bestandteilen (Elektronen, Ionen und Neutralgasatome) auch kleine Festkörperpartikel enthält. Die Durchmesser der Partikel liegen meist in der Größenordnung von wenigen Nanometern bis hin zu mehreren Mikrometern und somit sind sie deutlich größer als die restlichen Bestandteile des Plasmas. Die Partikel bieten eine Oberfläche, die ebenfalls durch das Zusammenstoßen mit Elektronen und Ionen elektrisch aufgeladen werden kann. Da sich in den Laborplasmen mit Argongas die Elektronen viel schneller als die Ionen bewegen können, laden sich die Staubteilchen in der Regel negativ auf.

2.2.1 Aufladung der Staubpartikel

Um den Aufladungsprozess der Staubteilchen zu beschreiben, bedient man sich der orbital motion limit-Theorie (kurz OML-Theorie), welche auf Mott-Smith und Langmuir zurückgeht [12]. Dabei betrachtet man ein Plasma, in dem die Geschwindigkeiten der Ladungsträger der Maxwell-Boltzmannverteilung entsprechen und die Staubpartikel an einem festen Ort ruhen. Dies ist durch den großen Geschwindigkeitsunterschied zwischen Ladungsträgern und Staubkörnern auch eine gute Näherung. Außerdem betrachtet man negativ geladene Staubpartikel, da nur diese für uns relevant sind. Die Staubpartikel werden im Plasma von Ionen und Elektronen getroffen, die Ladungen auf das Staubteilchen übertragen. Beschreiben lässt sich das durch einen Ionen- und einem Elektronenstrom, welche die Ladung des Staubpartikels beeinflussen. Eine weitere Annahme ist, dass sich die Elektronen und Ionen auf stoßfreien Bahnen bewegen und nur durch die Coulombwechselwirkung mit dem Staubpartikel interagieren. Beim Aufladeprozess unterscheidet man zwischen zwei Fällen: einmal die Wechselwirkung des Staubpartikels mit den Ionen und im anderen Fall mit den

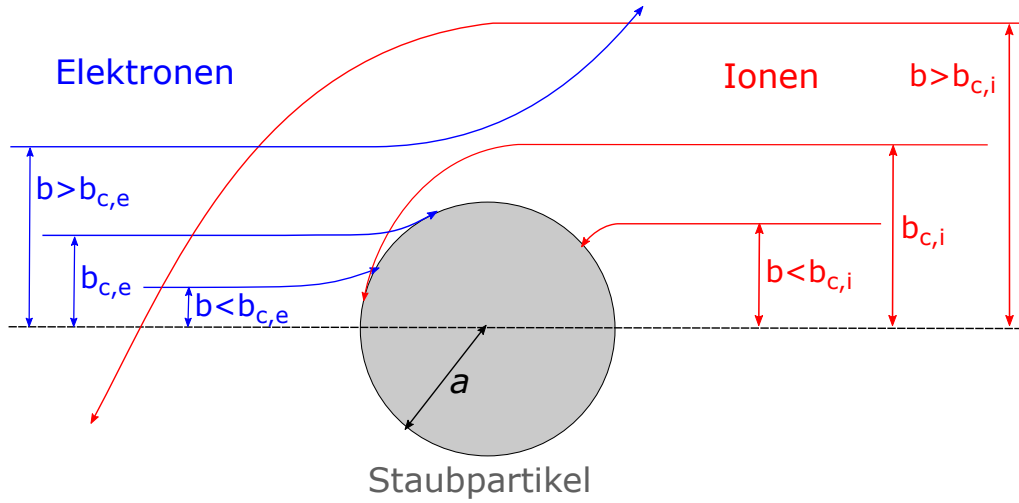


Abbildung 1: Schematische Darstellung der Ionen- und Elektronentrajektorien bei verschiedenen Stoßparametern, nach [13]

Elektronen im Plasma. Durch die positive Ladung der Ionen wirken auf sie anziehende Kräfte durch die negativ geladenen Partikel. Daher vergrößert sich der effektive Wirkungsquerschnitt über den geometrischen Querschnitt hinaus (siehe Abb.1). Um mit dem Staubteilchen zusammenstoßen zu können, müssen die Ionen einen Stoßparameter $b \leq b_{c,i}$ besitzen. Der Parameter $b_{c,i}$ gibt den maximalen Abstand des Ions an, bei dem es noch tangential auf das Teilchen trifft. Alle anderen Ionen mit einem größeren Stoßparameter werden lediglich von dem Staubpartikel abgelenkt. Betrachten wir ein Ion, das aus großer Entfernung mit der Geschwindigkeit v_{i0} und einem vertikalen Abstand dem kritischen Stoßparameter b_c entsprechend auf das Staubteilchen trifft, so bleiben sowohl der Drehimpuls

$$L = m_i v_{i0} b_{c,i} = m_i v_i a \quad (12)$$

als auch die Energie

$$E = \frac{1}{2} m_i v_{i0}^2 = \frac{1}{2} m_i v_i^2 + e\Phi_d \quad (13)$$

nach den Auftreffen erhalten. Dabei ist v_i die Geschwindigkeit des Ions nach dem Auftreffen, a der Radius des Staubteilchens und Φ_d das Potential des Staubteilchens [13]. Mit diesen Gleichungen lässt sich der kritische Stoßparameter für Ionen zu

$$b_{c,i}^2 = a^2 \left(1 - \frac{2e\Phi_d}{m_i v_{i0}^2} \right) \quad (14)$$

berechnen. Diesen kann man dann verwenden, um den Ionenstrom in Abhängigkeit

vom effektiven Stoßquerschnitt σ_c und der Stromdichte j_i in differenzieller Form zu bestimmen:

$$dI_i = \sigma_c dj_i = \sigma_c n_i e v_i f(v_i) dv_i \quad . \quad (15)$$

Integriert man diese Gleichung und nimmt eine Boltzmanverteilung für die Geschwindigkeiten der Ionen an, so erhält man den Ionenstrom

$$I_i = \pi a^2 n_i e \sqrt{\frac{8k_B T_i}{\pi m_i}} \left(1 - \frac{e\Phi_d}{k_B T_i} \right) \quad . \quad (16)$$

Ähnliches gilt für die Elektronen mit dem Unterschied, dass diese abstoßende Kräfte erfahren. Somit wird der effektive Wirkungsquerschnitt für die Elektronen kleiner als der geometrische Querschnitt. Der kritische Stoßparameter der Elektronen $b_{c,e}$ ist daher auch kleiner als der der Ionen. Dieser lässt sich analog zum kritischen Stoßparameter für die Ionen bestimmen und beträgt

$$b_{c,e}^2 = a^2 \left(1 + \frac{2e\Phi_d}{m_e v_{e0}^2} \right) \quad . \quad (17)$$

Der resultierende Elektronenstrom

$$I_e = -\pi a^2 n_e e \sqrt{\frac{8k_B T_i}{\pi m_i}} \exp\left(\frac{e\Phi_d}{k_B T_i}\right) \quad (18)$$

unterscheidet sich hauptsächlich durch den Exponentialterm, wobei in diesem Fall die Elektronen im Gegensatz zu den Ionen eine Mindestgeschwindigkeit $v_{\min} = \sqrt{-2e\Phi_d/m_e}$ benötigen, um das Staubteilchen zu treffen. Daher wird über das Intervall $v_{\min} \leq v_e \leq \infty$ integriert. Mit Hilfe dieser beiden Ströme lässt sich die Ladung eines Staubpartikels im Plasma bestimmen, da sich eine konstante Ladung des Teilchens erst dann einstellt, wenn beide Ströme gleich groß sind. Die Einstellung eines solchen Gleichgewichts ist vom elektrischen Potential des Staubteilchens abhängig. Das Potential, bei dem sich beide Ströme ausgleichen nennt man Floating-Potential Φ_{fl} . Betrachtet man nun die Staubpartikel als Kugelkondensatoren, so kann man dieses Potential nutzen, um die Ladung der Partikel zu berechnen. Im Vakuum gilt

$$Q_d = C\Phi_{fl} = 4\pi\epsilon_0 a \Phi_{fl} \quad , \quad (19)$$

was aber für ein Plasma allgemein zu

$$Q_d = 4\pi\epsilon_0 a \left(1 + \frac{a}{\lambda_D} \right) \Phi_{fl} \quad (20)$$

korrigiert werden muss. Da wir in der Regel aber mit Plasmen arbeiten, für die $a \ll \lambda_D$ gilt, ist Gleichung für den Vakuumfall eine gute Näherung.

2.3 Kräfte im staubigen Plasma

Durch das Hinzufügen von Staub in ein Plasma treten viele Effekte auf, die wir uns hier genauer anschauen wollen. Vor allem geht es darum, zu klären, warum sich der Staub so verhält wie man es in einem Plasma beobachten kann.

2.3.1 Gravitationskraft

Für die meisten Experimente auf der Erde spielt die Gravitation eine wichtige Rolle. So übt sie auch auf die Staubteilchen eine Kraft aus. Sie ist gegeben durch

$$\vec{F}_g = m_d \vec{g} = \frac{4}{3} \pi a^3 \rho_d \vec{g} \quad (21)$$

und somit von der Erdbeschleunigung \vec{g} , der Massendichte des Staubs ρ_d und des Radius der Staubkörner a in der dritten Potenz abhängig. Somit steigt die Gravitationskraft schnell mit zunehmender Staubgröße.

2.3.2 Elektrische Feldkraft

Auch das elektrische Feld im Plasma übt eine Kraft aus. Nach (19) ergibt sich die elektrische Feldkraft zu

$$\vec{F}_E = Q_d \vec{E} = 4\pi \varepsilon_0 a \Phi_d \vec{E} \quad . \quad (22)$$

Darin ist \vec{E} das elektrische Feld. Auffällig ist die Abhängigkeit vom Radius der Staubpartikel in erster Potenz. Das bedeutet, dass der Einfluss der elektrische Feldkraft mit steigendem Radius der Gravitationskraft unterliegt. Im Gegensatz zur Gravitationskraft ist die elektrische Feldkraft durch das ortsabhängige elektrische Feld vom Ort abhängig.

2.3.3 Thermophorese

Thermophorese bezeichnet das Phänomen, dass sich Teilchen wie zum Beispiel Staub bei einen großen Temperaturgradienten des flüssigen oder gasförmigen Mediums zum kalten Bereich hinbewegen. Da in dem Fall Temperatur nichts anderes als ein Maß für die Geschwindigkeit der Neutralgasatome ist, kann man diese Kraft damit begründen, dass die Staubkörner von der warmen Seite einen höheren Impuls von den Neutralgasatomen übertragen bekommen als von der kalten Seite. Somit gibt es einen Gesamtimpuls in Richtung der kalten Seite. Nach [13] ist die thermophoretische Kraft gegeben durch

$$\vec{F}_{th} = -\frac{32}{15} \frac{a^2 k_n}{v_{th,n}} \vec{\nabla} T_n \quad . \quad (23)$$

Darin sind $\vec{\nabla}T_n$ der Temperaturgradient, k_n die thermische Leitfähigkeit des Neutralgases und $v_{th,n}$ dessen mittlere thermische Geschwindigkeit.

2.3.4 Neutralgasreibung

Durch die Zusammenstöße zwischen Neutralgasatomen und den Staubpartikeln tritt noch eine weitere Kraft auf, die im Gegensatz zu den bisherigen Kräften keine einheitliche Richtung besitzt. P. S. Epstein beschrieb bereits 1924 diese Reibungskraft, um die Phänomene in Millikans Öltropfenexperiment zu erklären [14]. Danach enthält die Reibungskraft

$$\vec{F}_n = -m_d \beta v_d \quad (24)$$

den Epstein-Reibungskoeffizienten

$$\beta = \delta \frac{8}{\pi} \frac{p}{a \rho_d v_{th,n}} \quad . \quad (25)$$

Hier ist m_d die Masse und ρ_d die Dichte des Staubpartikels, v_d seine Relativgeschwindigkeit zu den Neutralgasatomen, p der Druck des Gases, sowieso $v_{th,n}$ die Geschwindigkeit der Neutralgasatome. Der einheitslose Parameter δ beschreibt den Impulsübertrag bei einem Zusammenstoß. Er liegt zwischen 1 bei spiegelnder Reflexion und 1,44 bei diffuser Streuung.

2.3.5 Ionenwind

Auch die Ionen können mit den Staubpartikeln stoßen und somit eine Kraft \vec{F}_{dir} ausüben. Durch ihre positive Ladung üben sie sogar ohne Zusammenstoß allein durch die Coulombwechselwirkung eine Kraft \vec{F}_{Coul} auf die Teilchen aus. Zusammen werden diese Phänomene als Ionenwindkraft \vec{F}_{ion} beschrieben:

$$\vec{F}_{ion} = \vec{F}_{dir} + \vec{F}_{Coul} \quad . \quad (26)$$

Die Kraft \vec{F}_{dir} , die durch direkte Zusammenstöße von Ionen mit dem Staubpartikel verursacht wird, kann analog zum Aufladeprozess mit der OML-Theorie beschrieben werden. Statt einer Maxwell-Verteilung der Geschwindigkeiten wird eine einheitliche Strömungsgeschwindigkeit angenommen und so ergibt sich die Kraft nach Barnes [15] zu

$$\vec{F}_{dir} = \pi a^2 n_i m_i v_s \vec{u}_i \left(1 - \frac{2e\Phi_d}{m_i v_s^2} \right) \quad . \quad (27)$$

Darin sind n_i die Dichte, m_i die Masse und u_i die Strömungsgeschwindigkeit der

Ionen. Φ_d bezeichnet das elektrische Potential des Staubteilchens. Die Geschwindigkeit v_s berechnet sich aus der thermischen Geschwindigkeit $v_{th,i}$ sowie der Strömungsgeschwindigkeit u_i der Ionen gemäß

$$v_s = \sqrt{v_{th,i}^2 + u_i^2} \quad . \quad (28)$$

Bei der Kraft \vec{F}_{Coul} , die allein durch Coulombwechselwirkung entsteht, haben alle Ionen einen Stoßparameter größer dem kritischen Stoßparameter b_c . Außerdem wird der mögliche Stoßparameter nach oben hin durch die Debye-Länge λ_D beschränkt, da darüber hinaus das Potential des Partikels schon zu sehr abgefallen ist. Somit gilt für den Stoßparameter $b_c < b < \lambda_D$. Der Stoßquerschnitt ist nach [13] gegeben durch

$$\sigma = 4\pi b_{\pi/2}^2 \ln \left(\frac{\lambda_D^2 + b_{\pi/2}^2}{b_c^2 + b_{\pi/2}^2} \right)^{\frac{1}{2}} \quad , \quad (29)$$

wobei $b_{\pi/2}$ der Stoßparameter ist, bei dem das Ion um 90° abgelenkt wird. Er lässt sich berechnen mittels

$$b_{\pi/2} = \frac{Z_d e^2}{4\pi\epsilon_0 m_i v_i^2} = \frac{ae\Phi_p}{m_i v_s^2} \quad , \quad (30)$$

wobei Φ_p das Potential des Plasmas ist. Daraus ergibt sich die Coulombkraft zu

$$\vec{F}_{Coul} = 4\pi b_{\pi/2}^2 n_i m_i v_s \vec{u}_i \ln \left(\frac{\lambda_D^2 + b_{\pi/2}^2}{b_c^2 + b_{\pi/2}^2} \right)^{\frac{1}{2}} \quad (31)$$

$$= 2\pi \frac{a^2 e^2 \Phi_p^2}{m_i v_s^3} n_i \vec{u}_i \ln \left(\frac{\lambda_D^2 + b_{\pi/2}^2}{b_c^2 + b_{\pi/2}^2} \right) \quad . \quad (32)$$

Die gesamte Ionenwindkraft ergibt sich durch Addition der Stoßkraft und der Coulombkraft.

2.3.6 Gesamtheit der Kräfte

Bei Staubteilchen in der Größenordnung von einigen Mikrometern dominiert die Gravitationskraft gegenüber der elektrischen Feldkraft. Sie hängt von der dritten Potenz des Radius der Staubteilchen ab, während die elektrische Feldkraft nur von der ersten Potenz abhängig ist. Die elektrische Feldkraft ist am Rand des Plasmas am größten, da dort die Quasineutralität am stärksten verletzt ist. Da die Gravitationskraft die Teilchen nach unten zieht, führt das dazu, dass sich die Teilchen nicht im oder am Rand des Plasmas sammeln, sondern in der sog. unteren Randschicht. Dort

wirkt die elektrische Feldkraft der Gravitationskraft und dem Ionenwind entgegen, was zu einem Kräftegleichgewicht führt und die Teilchen zum Schweben bringt.

2.4 Neuronale Netze

Neuronale Netze sind Programme, die der Funktionsweise von organischen Neuronen nachgeahmt sind. Ähnlich wie das menschliche Gehirn können sich auch neuronale Netze durch einen Lernprozess entwickeln und somit dazulernen. Die Struktur der Netz ist in layer gegliedert (siehe Abb. 2), wobei Informationen nur von einem layer zum benachbarten weitergegeben werden. Jedes layer selbst besteht aus Neuronen, die die Daten verarbeiten. Dabei gilt das feedforward-Prinzip, was bedeutet, dass die Informationen nur in eine Richtung weitergegeben werden. Der output eines Neuron ist ein Teil des input des nächsten Neurons, da jedes Neuron seine Information an alle Neuronen im nächsten layer weitergibt und somit auch jedes Neuron von jedem Neuron im vorherigen layer Informationen erhält. Sie besitzen einen Schwellwert oder auch Bias genannt und für jeden Eingang eine Gewichtung. Durch Änderung dieser Parameter lernt das Netzwerk die Daten richtig auszuwerten. Die gezielte Anpassung erfolgt durch das Nutzen von Trainingsdaten und der Vergleich der Ergebnisse des Netzwerkes mit den richtigen Ergebnissen.




Abbildung 2: Schematische Darstellung des Aufbaus eines neuronalen Netzes mit Gewichtung w , Bias b , Zustandssumme z und Aktivitäten a

2.4.1 Datenverarbeitung

Jedes Neuronale Netz besitzt ein input layer, welches nur der Eingabe der Daten dient. Diese Daten werden nun an jedes Neuron im nächsten layer weitergegeben.

Diese verarbeiten die eingegangenen Daten anhand einer Aktivierungsfunktion. Die bekanntesten sind die Sigmoidfunktion

$$\sigma(z_j^l) \equiv \frac{1}{1 + \exp(z_j^l)} \quad (33)$$

und die ReLU-Funktion (rectified linear unit)

$$y = \begin{cases} 0, & \text{wenn } z_j^l < 0 \\ z_j^l, & \text{wenn } z_j^l \geq 0 \end{cases} \quad (34)$$

Darin ist $z_j^l = (\sum_k w_{jk}^l a_k^{l-1} + b_j^l)$ die gewichtete Summe vom j-ten Neuron im l-ten layer. Die Gewichtungen vom k-ten Neuron im (l-1)-ten layer zum j-ten Neuron im l-ten layer w_{jk}^l sind in einer Matrix gespeichert. Hingegen sind die Aktivität, also der output vom k-ten Neuron im (l-1)-ten layer a_k^{l-1} und der Bias im j-ten Neuron im l-ten layer b_j^l Vektoren (siehe Abb. 2). Die Anwendung der Sigmoid- oder der ReLU-Funktion auf die gewichtete Summe ergibt die Aktivität des Neurons. Im Fall der Sigmoidfunktion ist $a_j^l = \sigma(z_j^l)$ und bei der ReLU-Funktion gilt $a_j^l = y$. Der output eines Neuron baut also auf den outputs der Neuronen im vorherigen layer auf.

2.4.2 Lernprozess

Im Lernprozess sollen die einzelnen Gewichtungen und Bias so angepasst werden, dass das Ergebnis immer mehr der Erwartung entspricht. Dazu nutzt man Trainingsdaten, von denen man die richtigen Ergebnisse kennt. Bei der Handschriftserkennung von Zahlen wären es also beispielsweise Bilder, bei denen man vorher die Zahlen selbst bestimmt hat. Das Netzwerk bekommt jetzt die Trainingsdaten als auch die richtigen Ergebnisse. Die Daten werden wie zuvor beschrieben vom Netzwerk verarbeitet und zum Schluss wird das Ergebnis mit dem richtigen Ergebnis verglichen. Um die Qualität des Ergebnisses zu definieren, führt man eine Kostenfunktion ein. Häufig wird dabei die quadratische Kostenfunktion

$$C(w,b) = \frac{1}{2n} \sum_x \|y(x) - a\|^2 \quad (35)$$

verwendet, wobei $y(x)$ das richtige Ergebnis und a das vom Netzwerk gelieferte Ergebnis ist. Ziel ist es jetzt diese Kostenfunktion zu minimieren. Dies ist vor allem durch das Anpassen von Gewichtungen und Bias möglich. Man nutzt dazu den Ansatz

$$\Delta C(v_1, v_2) \approx \frac{\partial C}{\partial v_1} \Delta v_1 + \frac{\partial C}{\partial v_2} \Delta v_2 \quad , \quad (36)$$

der sich in Vektorschreibweise zu $\Delta C \approx \nabla C \cdot \Delta v$ verkürzt. Wenn man nun $\Delta v = -\eta \nabla C$ definiert, dann ergibt sich für eine kleine Änderung der Kostenfunktion

$$\Delta C \approx -\eta \|\nabla C\|^2 \quad . \quad (37)$$

Diese Änderung ist immer negativ, solange die Lernrate η positiv ist. Sie sollte nicht zu groß gewählt werden, um große Minima der Kostenfunktion nicht zu überspringen, aber auch nicht zu klein sein, damit das Netzwerk nicht zu lange zum Lernen braucht. Mit diesem Ansatz werden die Gewichtungen und Bias gemäß

$$w_k \rightarrow w'_k = w_k - \eta \frac{\partial C}{\partial w_k} \quad (38)$$

$$b_l \rightarrow b'_l = b_l - \eta \frac{\partial C}{\partial b_l} \quad (39)$$

angepasst. Bei einem neuronalen Netz mit vielen layer kann man mit diesem einfachen Gradientenabstieg nicht alle Gewichtungen und Bias anpassen, da der Fehler nur im output layer berechnet wird. Daher nutzt man backpropagation, ein Verfahren, das dem feedforward genau entgegengesetzt abläuft und den Fehler im output für die einzelnen Neuronen in den layers zurückrechnet. Der Fehler im output layer ergibt sich zu

$$\delta_j^L = \frac{\partial C}{\partial z_j^L} = \sum_k \frac{\partial C}{\partial a_k^L} \frac{\partial a_k^L}{\partial z_j^L} = \frac{\partial C}{\partial a_j^L} \frac{\partial a_j^L}{\partial z_j^L} \quad . \quad (40)$$

Er ist also von der Kostenfunktion C und den Aktivitäten a_j^L sowie den gewichteten Summen z_j^L im output layer abhängig. Die Fehler im vorherigen layer setzt man nun in Abhängigkeit des Fehlers im Folgelayer zu

$$\delta_j^l = \frac{\partial C}{\partial z_j^l} = \sum_k \frac{\partial C}{\partial z_k^{l+1}} \frac{\partial z_k^{l+1}}{\partial z_j^l} = \sum_k \delta_k^{l+1} \frac{\partial z_k^{l+1}}{\partial z_j^l} \quad . \quad (41)$$

Mit Hilfe dieser Fehler kann man nun die Änderungen aus Gl. (39) berechnen:

$$\frac{\partial C}{\partial b_j^l} = \frac{\partial C}{\partial z_j^l} \frac{\partial z_j^l}{\partial b_j^l} = \delta_j^l \quad (42)$$

$$\frac{\partial C}{\partial w_{jk}^l} = \frac{\partial C}{\partial z_j^l} \frac{\partial z_j^l}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad . \quad (43)$$

Damit lassen sich die Parameter in dem Netzwerk leichter anpassen.

3 Messaufbau und Durchführung

3.1 Aufbau

Das Wichtigste für die Messungen ist das Plasma, welches in einer Plasmakammer erzeugt wird. Diese wurde zuvor auch schon in anderen Arbeiten wie [16, 17] verwendet. Der gesamte Messaufbau ist in Abb. 3 zu sehen. Die Kammer hat einen Durchmesser von 25 cm und besitzt insgesamt 6 Fenster für die Kameras und die Laser. Sie wird zuerst mit einer Vakuumpumpe entlüftet, sodass der Innendruck auf unter 1 Pa abfällt, und anschließend mit Argongas gefüllt. Der Betriebsdruck liegt etwa zwischen 5 und 15 Pa. Gezündet wird das Plasma durch Anlegen einer HF-Spannung. Dazu befindet sich am Boden der Plasmakammer eine runde Messingelektrode mit einem Durchmesser von 10 cm, die über ein Anpassungsnetzwerk mit einem HF-Generator verbunden ist und mit einer Frequenz von $f = 13,5$ MHz betrieben wird. Durch die Nutzung der kapazitiven Kopplung und des Anpassungsnetzwerks kann die reflektierte Leistung auf fast 0 W gesenkt werden. Um reflektiertes Laserlicht zu reduzieren, besitzt die Elektrode eine geschwärzte Aluminiumplatte, die auf der Messingelektrode liegt. Als Gegenelektrode dienen die geerdeten Wände der Plasmakammer. Die Zündung des Plasmas erfolgt bei etwa 10 W. Für die Messungen wird die Leistung jedoch auf 0,5 – 2,5 W abgesenkt. Einige Zentimeter über der Bodenelektrode befindet sich ein Messingring mit einem Radius von 1,2 cm. Er ist gut geeignet um kleine, kugelförmige Cluster einzufangen [18]. Der Ring ist mit dem Deckel der Kammer verbunden, ist jedoch durch ein Polymer elektrisch isoliert und damit nicht geerdet. Stattdessen nimmt der Ring das Floating-Potential an. Um die Staubteilchen für die Kameras sichtbar zu machen, ist eine hohe Intensität an Licht erforderlich, damit genügend Licht reflektiert wird. Dazu dienen zwei Laser mit einer Wellenlänge von 665 nm. Sie sind so ausgerichtet, dass sie die Staubwolke gut beleuchten, aber nicht die Kameras blenden. Die Justierung findet über zwei Spiegel statt, die den Strahlengang der Laser bestimmen. Die unteren und die oberen Kameras befinden sich je in etwa 90°-Winkel zueinander und sind mittig vor den Fenstern der Kammer positioniert. Die beiden oberen Kameras stehen zu den Unteren im über 70°-Winkel, um möglichst unterschiedliche Perspektiven aufzunehmen. Sie sind durch das Fenster im Deckel auf das Cluster gerichtet. Somit werden sowohl von der Seite als auch von oben Bilder aufgenommen. Alle vier Kameras werden über einen Funktionsgenerator getriggert, sodass sie synchron Bilder aufnehmen können. Sie sind von der Marke „MIKROTRON“ (Modell: „EoSens CL MC1362“) und nehmen mit einer Auflösung von 1.280×1.024 Pixel mit bis zu 506 Bildern pro Sekunde (fps) auf. Jede wurde mit einem 200 mm Makro-Objektiven ergänzt, welche besonders geeignet sind um kleine Objekte in kurzer Entfernung aufzunehmen. Der Staub befindet sich in einem schwenkbaren Löffel im oberen Bereich der Plasmakammer. Er ist so am Deckel der Kammer befestigt dass man ihn von außen drehen kann. Zum Injizieren des Staubs wird der Löffel ziemlich genau über das Plasma gedreht, sodass man durch klopfen an der Halterung Staub in das Plasma rieseln lassen kann.

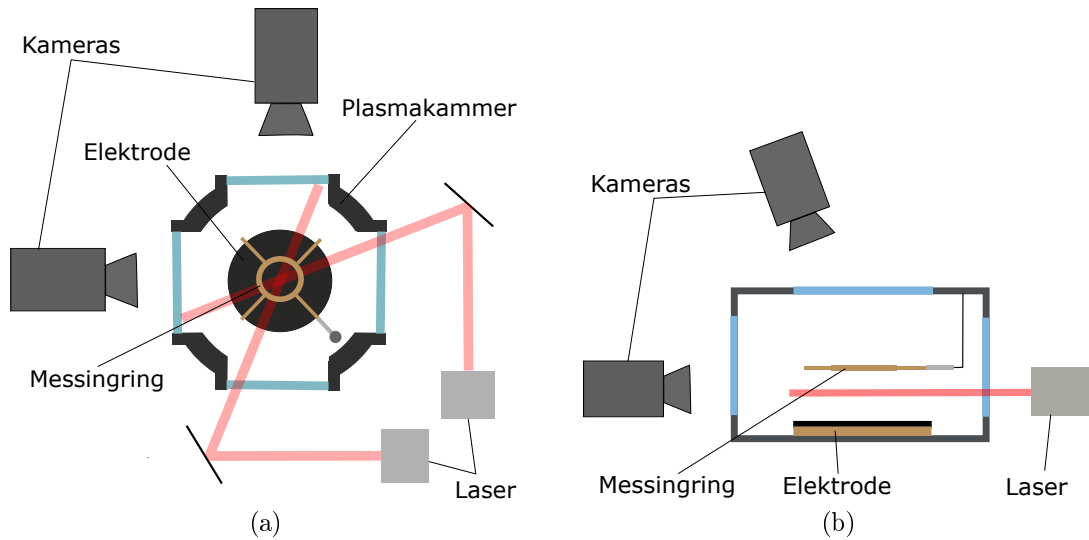


Abbildung 3: Skizze des Versuchsaufbaus (a) von oben und (b) von der Seite.

3.2 Messungen

Ziel der Messungen waren kleine und kompakte Cluster mit 50 bis 150 Teilchen einzufangen. Nach Zugabe des Staubes kann durch die Variation der Leistung des HF-Generators sowie des Neutralgasdrucks die Position und räumliche Ausdehnung der Staubwolke beeinflusst werden. Die Aufnahmen werden über die Software „StreamPix“ gemacht, wo die Anzahl der frames und die fps eingestellt werden. Es wurden zwei Messungen mit 50 fps mit je 1000 frames aufgenommen. Verwendet wurde ein Staub aus MF-Forschungspartikeln der Größe $(3,81 \pm 0,09) \mu\text{m}$. Die erste Messung erfolgte bei einem Druck von 8,4 Pa und einer HF-Leistung von 0,7 W. Bei der zweiten Messung wurden ähnliche Parameter verwendet. Der Druck lag bei 10 Pa und die HF-Leistung bei 0,7 W.

3.3 Auswertung der Messdaten

Zur Auswertung werden die Bilder mit Hilfe der Projektionsmatrizen aus der Kalibrierung in ein 3D-Volumen projiziert. Den genauen Ablauf der Kalibrierung und die verwendeten Programme der Stereo- und der AIPR-Toolbox sind unter [19, 20] zu finden. Dieses dreidimensionale Volumen wurde vorher in voxels unterteilt, so dass das Volumen mit einem $N_x \times N_y \times N_z$ großem Feld beschrieben werden kann. Jedes voxel nimmt die auf ihn projizierte Intensität an, wodurch das Feld sozusagen die Aufenthaltswahrscheinlichkeit der Teilchen aus einer Kameraperspektive beschreibt. Die Felder $I_{i,1}$ bis $I_{i,4}$ aller vier Kameras werden für jedes einzelne frame zusammengerechnet und ergeben das initial field I_i . Dazu werden drei verschiedene Möglichkeiten getestet das initial field zu berechnen. Zum einen wird die 4. Wurzel genutzt, wie es auch in [10] beschrieben ist:

$$I_i = \left(\prod_N I_{i,N} \right)^{1/4} . \quad (44)$$

Dabei läuft N von 1 bis 4 und steht für die verschiedenen Kameraperspektiven. Außerdem wird auch der Durchschnitt der einzelnen Felder $I_{i,N}$ sowie eine Mischung aus beidem genutzt:

$$I_i = \frac{(\prod_N I_{i,N})^{1/4}}{2} + \frac{\sum_N I_{i,N}}{8} . \quad (45)$$

Nach Bearbeitung der Daten werden die erstellten initial field dem neuronalen Netz übergeben. Das neuronale Netz hat die Aufgabe diese initial field so zu bearbeiten, dass die Teilchen durch ein Auswertungsprogramm aus [20] leichter erkannt werden können. Ideal für das Programm ist eine etwa einheitliche Größe der Intensitätsverteilungen und eine möglichst große Differenz zwischen der Intensität der Teilchen und der Umgebung. Da nicht alle Teilchen im initial field und auch nicht im bearbeiteten prediction field die gleiche Intensität besitzen, wird ein Intensitätsintervall betrachtet, in dem mögliche Teilchen erkannt werden sollten. In jedem prediction field sucht das Programm nach mindestens 7 kompakt zusammenhängenden voxels, die die obere Intensitätsgrenze überschreiten und zählt diese als Teilchen. Die Position wird durch den Mittelpunkt der voxel-Verteilung bestimmt. Anschließend wird die Intensität dieser voxels auf Null gesetzt und die Intensitätsgrenze wird reduziert. In diesem Fall wurden in den meisten Fällen voxels im Intensitätsintervall von $0,7 - 0,05$ mit einer Schrittweite von $0,005$ betrachtet. Damit wird ein Intervall von $165,75$ Graustufen in $1,275$ Graustufenschrittweite abgedeckt.

3.4 Aufbau des neuronalen Netzes

Das Netzwerk orientiert sich an [21], wobei aber ein paar Änderungen vorgenommen wurden. Insgesamt besteht das Netzwerk aus 10 Schichten: einem erweitertem input und einem erweitertem output layer sowie 8 „Blöcke“ hidden layer. Der Aufbau ist auch in Abb. 4 zu sehen.

Das erste layer ist ein dreidimensionales Bild input layer, welches gerade so groß wie das initial field ist. Die dreidimensionale Matrix wird anschließend von einem würfelförmigen convolution filter der Größe $3 \times 3 \times 3$ bearbeitet, der sich über die Matrix bewegt. Damit die Größe der Matrix erhalten bleibt, wird diese zuerst in alle Richtungen mit einer Schicht aus Nullen erweitert. Dem angeschlossen ist ein batch normalization layer und ein ReLU layer. Die 8 „Blöcke“ im hidden layer bestehen wieder jeweils aus einem dreidimensionalen convolutional layer, aber diesmal mit 16 Neuronen, also 16 parallel geschalteten Filtern. Dem layer schließen sich wieder ein batch normalization und ein ReLU layer an. Zum Schluss laufen die Daten wieder durch einen convolution filter mit anschließender batch normalization. Diesmal wird




Abbildung 4: Netzwerkdesign mit unterschiedlichen Größen des convolutional layer. Im ersten und letzten Block ist je eins und in den 8 Blöcken des hidden layer 16 Neuronen enthalten. Aus [10]

im folgendem layer aber die Sigmoid- anstatt der ReLU-Funktion eingesetzt, um die Werte in der Matrix zwischen 0 und 1 zu halten, damit sie mit den Trainingsdaten verglichen werden können. Das output layer bildet ein regression layer, welches die Kostenfunktion beinhaltet. In diesem Fall wird folgende verwendet:

$$C = 1 - \frac{2 \sum (T \cdot Y)}{\sum T^2 + \sum Y^2} \quad (46)$$

Y ist dabei das bearbeitete initial field, also die prediction vom Netzwerk und T ist das trainig field, also die „richtigen“ Werte. Da sowohl T als auch Y dreidimensionale Matrizen sind, erfolgt die Addition über alle voxels und alle batches, während die Multiplikation dem Hadamard-Produkt entspricht.

3.5 Trainingsdaten und Trainingsablauf

Für die Trainingsdaten wird zuerst ein Quader im dreidimensionalen Projektionsraum ausgewählt, in dem sich auch die realen Teilchen aufhalten. In diesem Bereich werden mit einer einstellbaren Anzahl und Größe Teilchen in das Gitter generiert, was das training field bildet. Dabei werden zufällig Positionen in dem Bereich ausgewählt und gemäß einer Gaußverteilung die Intensität des voxels, welches die Partikelposition abdeckt, als auch der umliegenden voxels erhöht. Das training field hat dabei die gleiche Größe $N_x \times N_y \times N_z$ wie bei den Messdaten verwendet wird. Mit den Projektionsmatrizen aus der Kalibrierung werden künstliche Bilder erzeugt, die den Messbildern sehr ähnlich sind. Dazu werden an den projizierten Positionen normalverteilte Intensitätsverteilungen aufgetragen. Die Trainingsbilder werden anschließend genau wie die Messdaten so bearbeitet, dass die Teilchen runder und größer erscheinen. Mit den bearbeiteten Bildern und den Projektionsmatrizen wird das initial field generiert, welches von dem neuronalen Netz bearbeitet werden soll.

Das entstehende prediction field wird mit den originalen training field verglichen. Im Schnitt werden zwischen 1000 und 2000 Trainingsdatensätze generiert um, das Netzwerk zu trainieren. Jede Trainingsdatei enthält das training field, das initial field als auch die vier Bilder aus den verschiedenen Kameraperspektiven. Trainiert wird in drei Epochen mit einer Größe eines batche von einer Trainingsdatei, weshalb nach jedem Durchlauf eines einzelnen Trainings-initial field eine backpropagation stattfindet. Diese Methodik hat sich nach [10] als sinnvoll erwiesen. Die Startparameter der Gewichtungen in den convolution filters sind zufällig, während die Bias am Anfang auf Null gesetzt sind. Die anfängliche Lernrate beträgt 0,1 und wird nach jeder Epoche um einen Faktor von 0,1 oder 0,05 (je nach Auswertung) verringert. Dies ist der learn drop rate factor. Das Training der Neuronalen Netze erfolgt im Folgenden immer in 3 Epochen. So beträgt bei einer anfänglichen Lernrate von 0,1 und einem learn drop rate factor von 0,1, die Lernrate in der ersten Epoche 0,1, in der Zweiten 0,01 und in der letzten Epoche nur noch 0,001. Somit verlangsamt sich der Trainingsfortschritt mit jeder Epoche.

4 Auswertungen mit der ersten Messung

4.1 Generierung der Trainingssets

Für die erste Messung, mit der die meisten Auswertungen gemacht wurden, wurde ein zu betrachtendes Volumen von $-3 \text{ mm} \leq x \leq 0 \text{ mm}$, $-1 \text{ mm} \leq y \leq 1,5 \text{ mm}$ und $606 \text{ mm} \leq z \leq 610 \text{ mm}$ mit einer Größe der voxels von $0,02 \text{ mm} \times 0,02 \text{ mm} \times 0,04 \text{ mm}$ gewählt. Die Größe der voxels ist nach unten durch die maximale Anzahl der voxels, welche wiederum vom Speicher in der GPU abhängt, limitiert. Genutzt wurde eine NVIDIA GeForce RTX 2080 Ti mit 18,8 GB Speicherkapazität. Innerhalb dieses Volumens wurden 200 zufällige Teilchenpositionen generiert. Mit Hilfe der Projektionsmatrizen wurden diese Positionen in die vier Bildebenen übertragen. Da die Originalbilder im Hintergrund meist nicht komplett schwarz sind, wurde eine Grundintensität von 0,007 über alle Trainingsbilder gelegt. Bei den 8Bit-Kameras macht das knapp 1,8 Graustufen aus, was immer noch sehr gering ist. Die Normalverteilung zum Auftrag der Intensitäten der künstlichen Teilchen erfolgt mit einem für jedes Teilchen zufälligen Vorfaktor zwischen 0,2 und 0,8, was 51 bis 204 Graustufen entspricht. Die Größe der künstlichen Teilchen ist durch eine Varianz von einem Pixel eingestellt. Mit diesen Einstellungen sehen die Teilchendichte und -intensitäten auf den Trainingsbilder den der Messbilder sehr ähnlich. Anschließend werden die Bilder mit zwei Sobel- und einem Gaußfilter bearbeitet. Zuerst wird jedes Bild einmal horizontal und einmal vertikal mit einem Sobelfilter bearbeitet, wobei dieser einen Vorfaktor von 0,5 besitzt. Die Intensitäten der Bilder werden anschließend mit der Wurzel der Summe der Intensitätsquadrate für jedes einzelne Pixel zusammengesetzt. Anschließend werden die Bilder mit einem 3×3 Pixel großen Gaußfilter mit einer Varianz von einem Pixel geglättet. Mit diesen bearbeiteten Bildern wird ein initial field berechnet, welches vor dem Training noch mit einem leichten Rau-

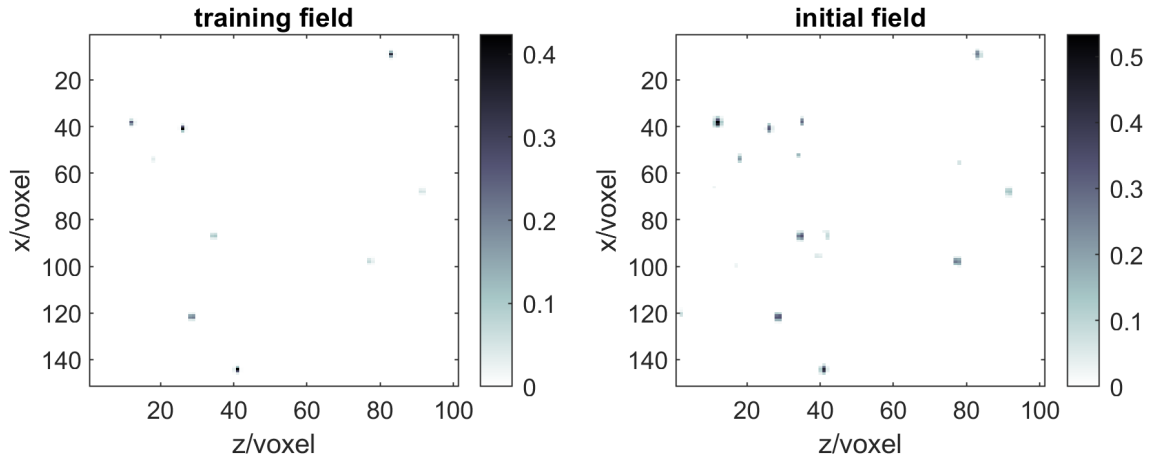


Abbildung 5: (links) Ausschnitt aus einem Training field bei $y = 65$ voxel; (rechts) der gleiche Ausschnitt aus dem, mit Gl. (44) berechneten, initial field

schen von 0 bis 7,65 Graustufen versehen wird. Im training field wird dagegen ein Vorfaktor vor der Normalverteilung zwischen 0,4 und 1 verwendet, was einer Intensität im Mittelpunkt von 102 bis 255 entspricht. Die Varianz der Normalverteilung beträgt $15\mu\text{m}$, wodurch die Intensitätsverteilungen der Teilchen einen Durchmesser von etwa 3-4 voxels haben. Der Durchmesser bezieht sich auf die Ausdehnung in X und Y . In Z -Richtung ist der voxel-Durchmesser nur etwa halb so groß, da die voxels in dieser Richtung doppelt so lang sind wie in X - und Y -Richtung. Die Angaben im folgenden Text beziehen sich daher auch immer auf die Ausdehnung in der XY -Ebene. Vergleicht man in Abb. 5 das training field und das initial field, welches mit Gl. (44) berechnet wurde, dann sieht man, dass sowohl die Intensitätsverteilungen als auch ihre maximale Intensität der Partikel sichtbar größer sind.

4.2 Berechnung der initial fields mittels der 4. Wurzel

Der erste Versuch orientiert sich direkt an den Ergebnissen von A. Melzer und M. Himpel [10], die bei einem ähnlichen Versuchsaufbau gute Ergebnisse erzielt haben. Daher wurde auch hier zur Berechnung des initial field die 4. Wurzel verwendet. Der Faktor zur Reduktion der Lernrate beträgt 0,1 und es wurden 2000 Trainingsdatensätze zum Trainieren des neuronalen Netzes verwendet. Zum Vergleich dient eine Auswertung der Messungen mit Hilfe der Stereo-Toolbox [19], die auch bei den folgenden Messungen immer wieder herangezogen wird, um die Qualität der trainierten neuronalen Netze zu beurteilen, wobei sich hier auf die Stabilität des Trainings konzentriert wird. Der „Shake-The-Box“ (STB)-Algorithmus ist eine gängige Methode um Partikeltrajektorien in staubigen Plasmen zu bestimmen. Für die folgenden Versuche ist aber nur die Position und Anzahl von Teilchen pro frame relevant, da die Bewegung der Teilchen nicht von Interesse ist und es lediglich um das Orten der Staubteilchen geht. Das Cluster, welches hier für die ersten Versuche betrachtet




Abbildung 6: Auswertung durch STB: Es ist zu sehen, dass das Cluster eine rundliche Gestalt und eine eher kleine räumliche Ausdehnung hat.

wird, enthält durchschnittlich etwa 79 Teilchen pro frame (siehe Abb. 6).

Da bei den ersten Trainingsdurchläufen des neuronalen Netzes auffällig war, dass die prediction fields nach Auswertung mit verschiedenen trainierten Netzen sehr unterschiedlich sein konnten, wurde das Netz zur Prüfung der Reproduzierbarkeit der Ergebnisse fünf mal mit dem selben Trainingsdaten trainiert und auf die gleichen Messbilder bzw. den berechneten initial fields angewandt. In Abb. 7 sieht man einem Ausschnitt aus dem initial field oben links im Vergleich zu den gleichen Ausschnitten aus den prediction fields. Sehr deutlich zu erkennen ist, dass die ersten drei trainierten Netzwerke die Intensität um mindestens 75% reduzieren. Bei dem Dritten ist dieser Effekt sogar so stark, dass dort Teilchen nicht einmal mehr erkannt werden können. Die Intensität in einem großen Bereich um die Teilchen herum wird sogar unter die Grundintensität gesenkt. Auch wenn in den predictions 1 und 2 immer noch die Teilchen erkennbar sind, so ist die Intensität zu gering um genug Teilchen detektieren zu können. Bei einer Reduktion des unteren Intensitätsschwellwertes auf weniger als 0,05 kommt es zur vermehrten Detektion von Ghostpartikeln, die durch Hintergrundrauschen oder Doppelzählung von zu wenig komprimierten Intensitätsverteilungen der Teilchen entstehen. Das fünfte Netzwerk hingegen behält die Intensität bei und verkleinert auch die Teilchengröße von 3 – 6 voxels im Durchmesser im initial field auf 3 – 4 voxels. Auch wenn die Intensität bei dem vierten Trainingsdurchgang halbiert ist, so sind alle Teilchen trotzdem deutlich abgegrenzt und auch ähnlich gut komprimiert wie in der fünften prediction.

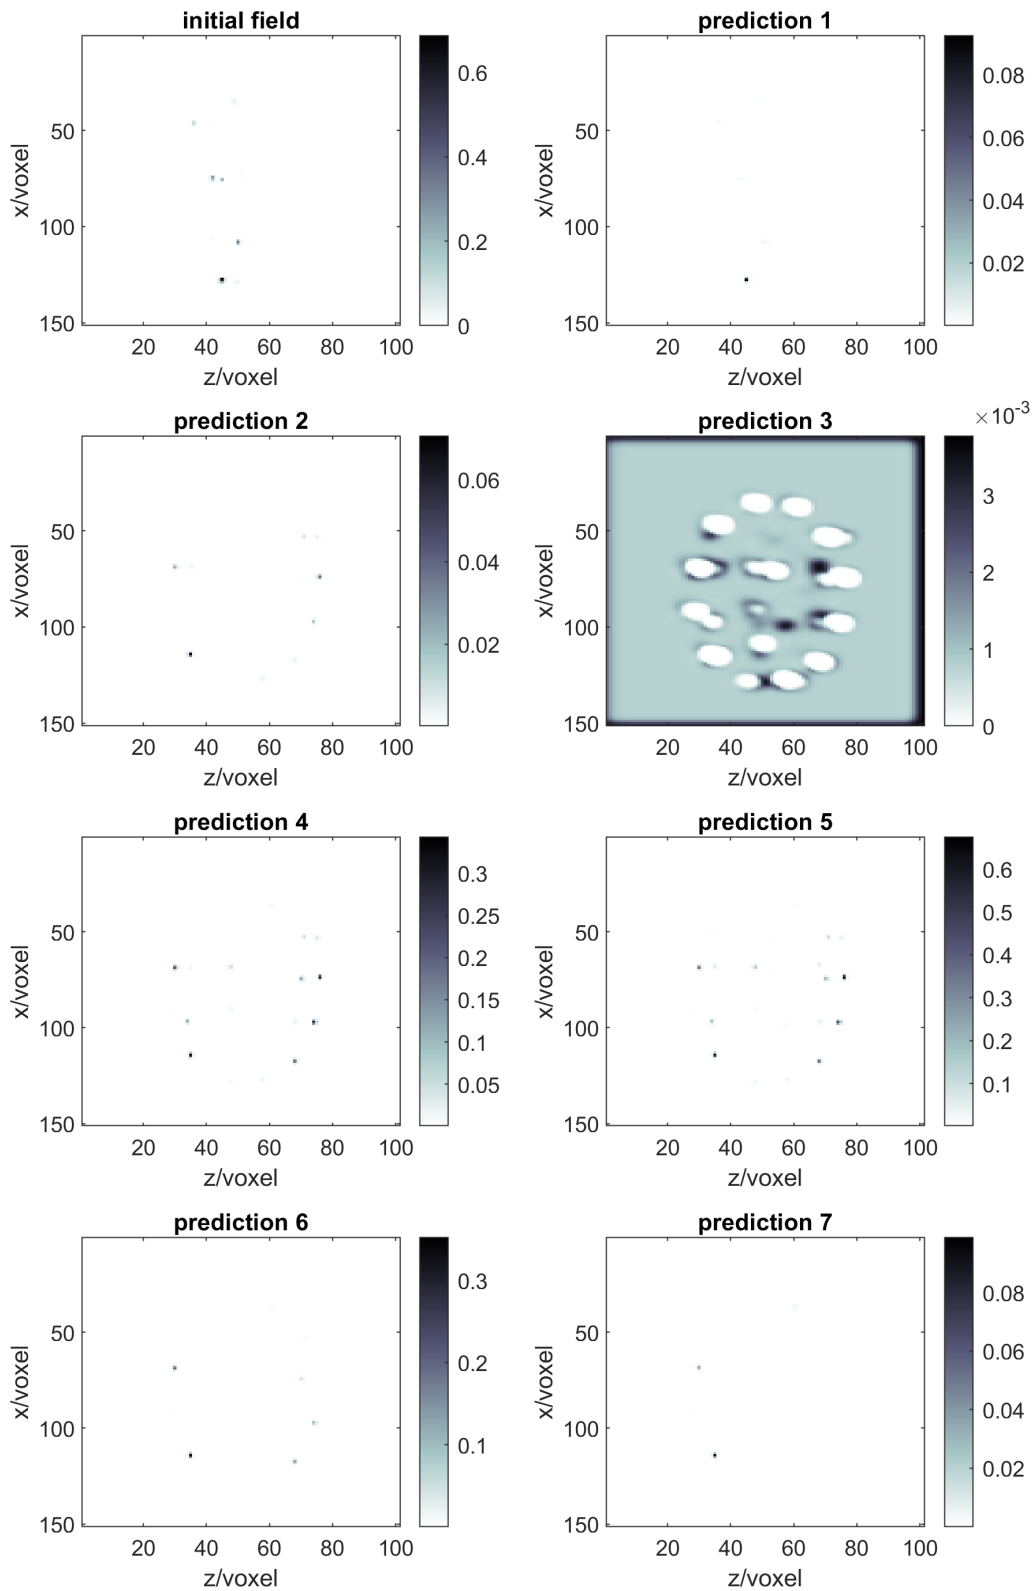


Abbildung 7: Ausschnitte aus dem initial field und aus prediction fields verschiedener Trainingsdurchläufe. Alle Ausschnitte sind bei $y = 60$ voxel. Die predictions 1-5 stammen von neuronalen Netzen, die mit den selben Trainingsdaten trainiert, während die predictions 6 und 7 mit einem neuen Set trainiert wurden. Der learn drop rate factor betrug bei allen Trainings 0,1.

Zum Vergleich sind unten die beiden prediction fields von zwei Trainingsdurchläufen mit neuen Trainingsdaten. Auch hier bestätigt sich, dass das Netzwerk nach dem Training bei gleichen Bedingungen keine vergleichbaren Ergebnisse liefert. Die wechselhaften Ergebnisse des Trainings sind also unabhängig von den Trainingsdaten. Noch deutlicher sind die Unterschiede, wenn man mit einer unteren Intensitätsschwelle von 0,05 sich die durchschnittliche Anzahl der erkannten Teilchen pro frame anschaut (siehe Tab. 1).

Tabelle 1: Anzahl der durchschnittlich erkannten Teilchenzahlen pro frame N_{NN} der prediction fields der 7 trainierten neuronalen Netze. Für die Ortung wurden 7 kompakt zusammenhängende voxels in ein Intensitätsintervall zwischen 0,7-0,05 mit einer Schrittweite von 0,005 als Partikel gezählt.

Durchlauf	N_{NN}
1	0,7
2	0
3	0
4	49,7
5	89,1
6	35,5
7	13,4

In den prediction fields 4 und 5 lassen sich die meisten Teilchen orten. Das liegt zum einen an der höheren Intensität aber noch eher an der fast einheitlichen Größe der Intensitätsverteilungen der Teilchen. Auch in den predictions 6 und 7 lassen sich im Vergleich zu den ersten 3 predictions mehr Teilchen orten, obwohl die Intensität stark durch die trainierten Netze reduziert wurde. Auch wenn dadurch viele Teilchen nicht mehr zu erkennen sind, so sind die übrigen sehr gut von der Umgebung abgegrenzt und komprimiert.

Eine mögliche Ursache für die unterschiedlichen Trainingsergebnisse könnte sein, dass die Lernrate in der letzten Epoche noch zu groß ist, sodass das Minimum der Kostenfunktion nicht nah genug erreicht wird. Dadurch könnte es zu großen Unregelmäßigkeiten im Training kommen. Aus diesem Grund wurde der Faktor zur Reduktion der Lernrate halbiert und weitere fünf Trainingsdurchläufe mit den gleichen Trainingsbildern wie bei der vorherigen 5er-Reihe gestartet. Auch hier ist wieder eine deutliche Unregelmäßigkeit in den prediction fields zu erkennen (Abb. 8). Die Intensität wird von den trainierten Netzen jedoch nicht so stark reduziert und variiert zwischen den predictions auch nicht mehr so stark wie zuvor. Alle 5 trainierten Netze komprimieren die Intensitätsverteilungen der Teilchen auf 3-4 voxels im Durchmesser. Bei der Betrachtung der Anzahl der durchschnittlich georteten Teilchen pro frame werden die Unterschiede zwischen den Auswertungen der verschiedenen trainierten Netze deutlicher. Dabei wurden wieder die gleichen Parameter wie zuvor

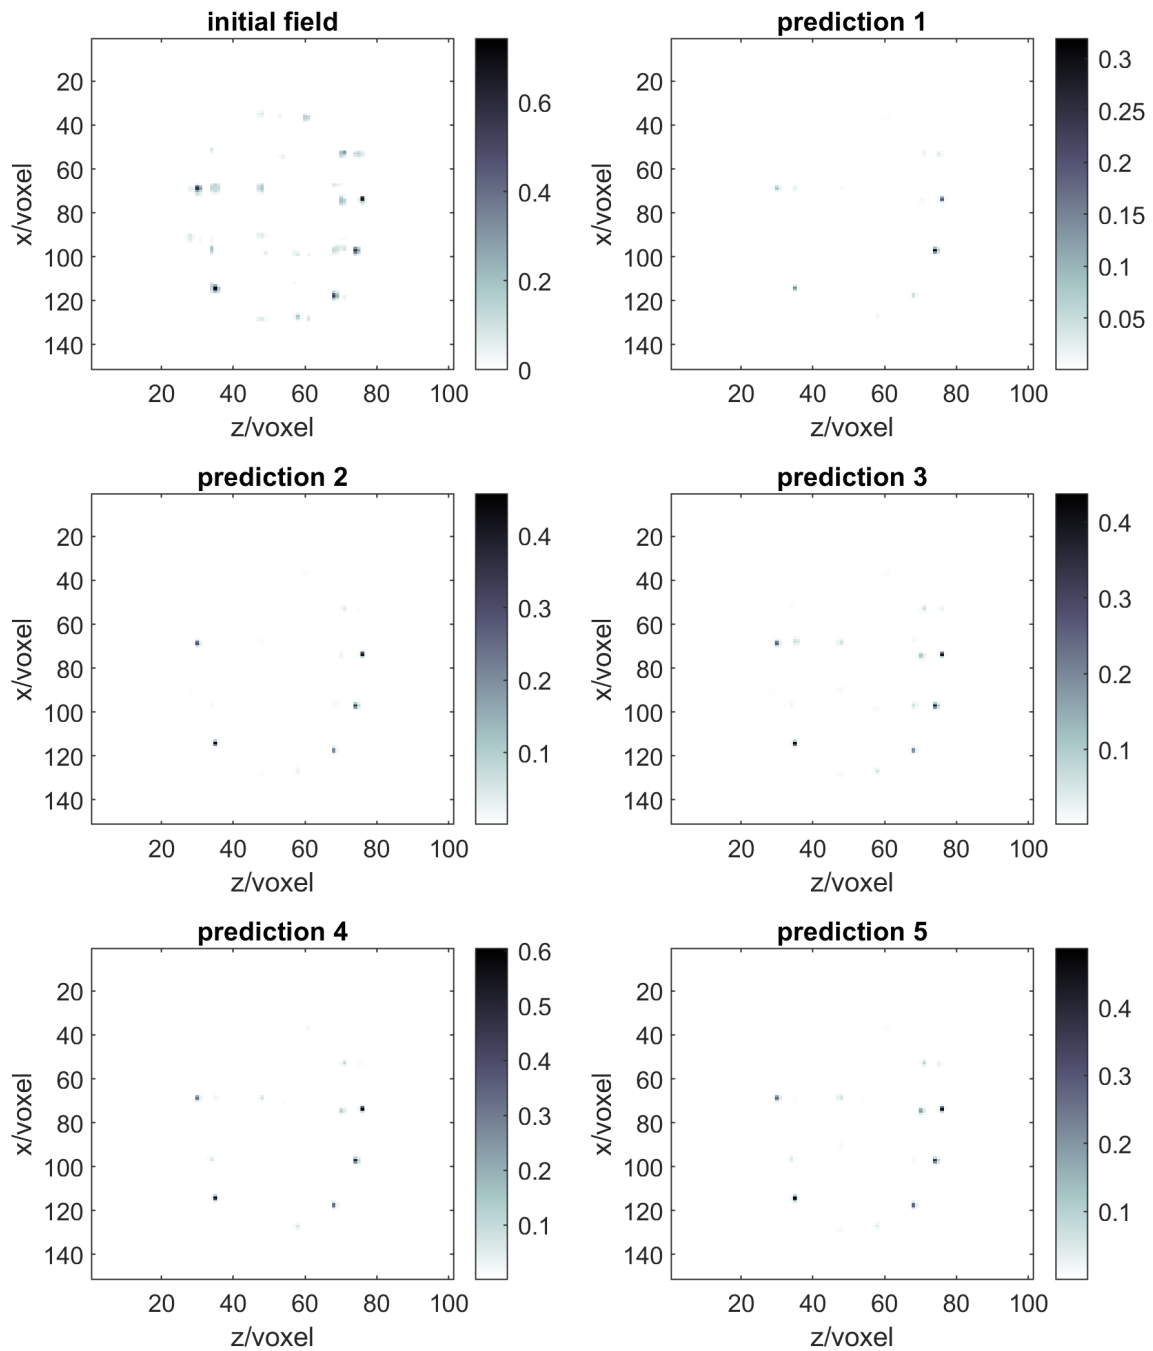


Abbildung 8: Gleicher frame und Ausschnitt bei $y = 60$ voxel wie zuvor. Die predictions stammen von neuronalen Netzen, die alle mit dem selben Trainingssets wie zuvor, aber mit einem learn drop rate factor von 0,05 trainiert wurden.

zur Teilchenerkennung genutzt. Wie in Tab. 2 zu sehen ist, gibt es große Schwankungen bei der erkannten Teilchenzahl. Auch wenn sich die predictions 3 und 5 augenscheinlich sehr ähnlich zu sehen scheinen, so wird unter gleichen Bedingungen bei prediction 3 nur etwa ein Teilchen pro frame erkannt und in prediction 5 71 Teilchen. Da die Intensität etwa vergleichbar ist, liegt die Ursache in der unterschiedlichen Komprimierung der Intensitätsverteilungen. Bei solch großen Schwankungen beim Training des neuronalen Netzes können keine zuverlässigen Auswertungen mit dem Netz gemacht werden.

Tabelle 2: Durchschnittliche Teilchenzahl pro frame nach Bearbeitung der gleichen initial fields mit 5 verschiedenen neuronalen Netzen, die mit dem selben Trainingsset bei einem Reduktionsfaktor der Lernrate von 0,05 trainiert wurden.

Durchlauf	N_{NN}
1	4,2
2	48,1
3	1,1
4	72,1
5	71,0

Eine Reduktion der Trainingsdaten auf 1000 Sets zeigte auch nur noch größere Schwankungen in den Ergebnissen. Die meisten Netzwerke reduzierten die Intensität der Teilchen so stark, dass sie nicht mehr zu erkennen waren (vgl. prediction 3 in Abb. 7). Das lag meist daran, dass die Lernrate oft zu schnell gesunken ist. Das Trainingsprogramm gibt für einen batch von 50 Trainingsdaten einen RMSE (root mean square error) aus, an dem zu erkennen war, dass bei den meisten Netzwerken die Lernrate zu schnell mit der nächsten Epoche sank, sodass der Fehler nicht schnell genug sinken konnte. Das Netzwerk braucht ein Minimum an Trainingsdurchläufen, bevor die Lernrate von 0,1 reduziert wird, um den RMSE zu senken. Dieses Minimum lag bei fast allen Trainingsdurchläufen unter 1200, weshalb die Anzahl der Trainingssets auf 1200 erhöht wurde (Abb. 9, prediction 1) und für zwei weitere Trainings dem neuronalen Netz wie in [21] 2 weitere Blöcke vom hidden layer hinzugefügt wurden (prediction 2 und 3). Auch wenn die Netzwerke nun nicht mehr die Intensität so stark reduziert haben wie zuvor, so waren sie trotzdem in der Auswertung sehr unterschiedlich. Während das erste und das dritte trainierte Netz die Intensitätsverteilungen der Staubteilchen gut komprimieren, so senkt das zweite trainierte Netz die Intensität der äußeren voxels der Intensitätsverteilung nicht stark genug ab, sodass die Intensitätsverteilungen noch einen Durchmesser von etwa 4-5 voxels besitzen. Im Vergleich dazu verkleinern die anderen beiden trainierten Netze die Intensitätsverteilungen von etwa 4-6 voxels im Durchmesser im initial field auf 3-4 voxels.

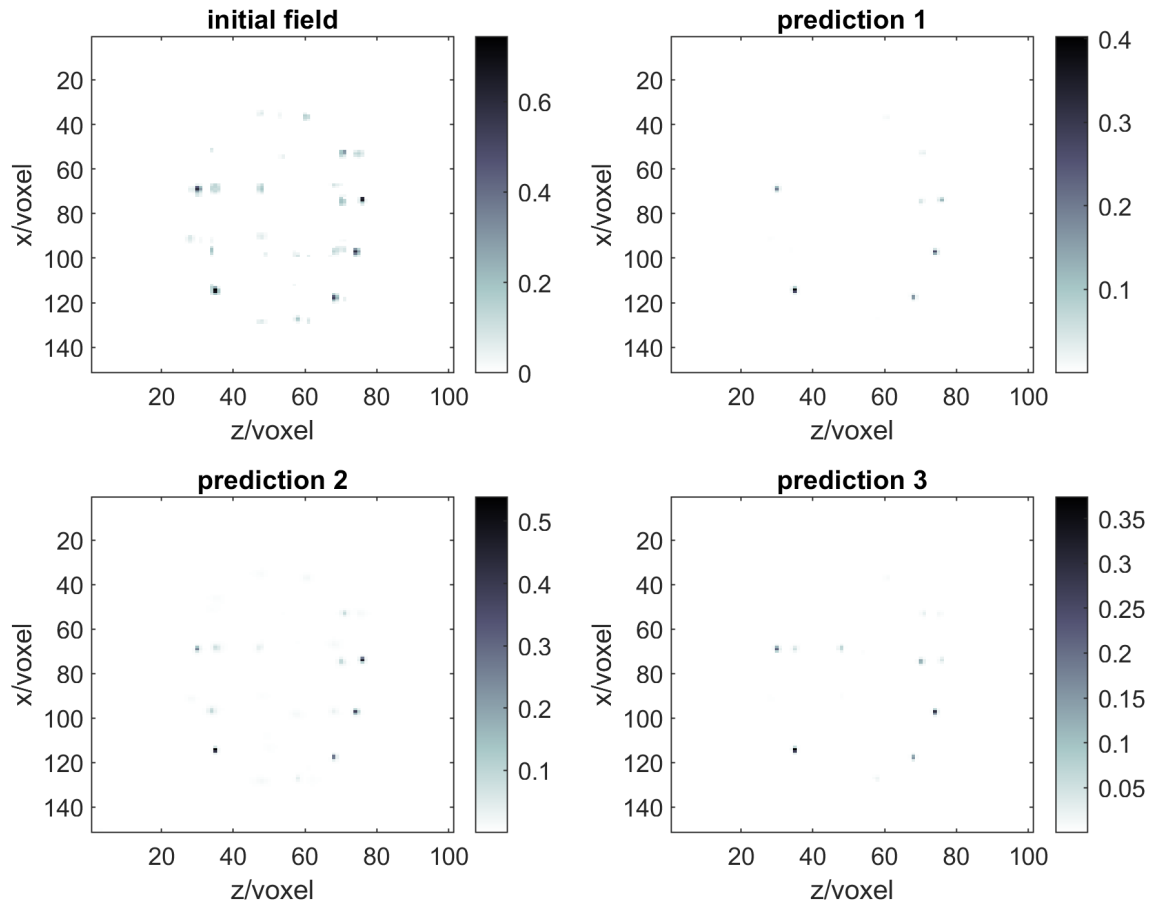


Abbildung 9: Ausschnitt an gleicher Stelle wie zuvor aus der prediction 1 bei 1200 Trainingssets und reduzierten learn rate drop factor von 0,05. Die Netze von predictions 2 und 3 wurden bei den gleichen Trainingsbedingungen trainiert, besitzen jedoch 2 zusätzlichen hidden layer-Blöcken. Zum Vergleich dient das initial field.

Die Größe der Intensitätsverteilungen der Teilchen muss zur Auswertung der Teilchenpositionen zwar nicht auf 3-4 voxels im Durchmesser reduziert werden, sondern nur auf einheitliche Größe, aber es zeigt Unterschiede in der Effektivität der Neuronalen Netze, da die Intensitätsverteilungen der Teilchen in den training fields einen Durchmesser von 3-4 voxels haben. Eigentlich war das Ziel mit dem Hinzufügen der beiden zusätzlichen layer-Blöcke dem Netz mehr Parameter zu geben um sich auf die Intensitätsverteilungen in den initial fields besser einstellen zu können und so zuverlässiger zu trainieren. Die großen Unterschiede zwischen prediction 2 und 3 zeigen aber, dass eine solche Erweiterung des Netzes nicht sinnvoll ist, um das Training zu stabilisieren. Die Unterschiede zwischen den trainierten Netzen wird in den durchschnittlichen Teilchenzahlen pro frame in Tab. 3 noch deutlicher. Diesmal wurden die Anteile der übereinstimmenden Teilchenpositionen mit einbezogen, um weitere Unterschiede zwischen den predictions deutlich zu machen.

Tabelle 3: Durchschnittliche Teilchenzahlen pro frame mit den Anteilen der Teilchen, die nach Auswertung durch das Neuronale Netz einen Abstand kleiner als 0,05 mm zu durch STB georteten Teilchen n_{NN} und umgekehrt n_{STB} haben.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	43,8	97,0	54,0
2	90,8	84,4	96,8
3	46,6	96,7	57,1

In den predictions mit geringerer Intensität der Teilchen sind diese auch schlechter zu orten, während in prediction 2 fast alle Teilchen aus STB gefunden werden können. Betrachtet man die absolute Anzahl von Teilchen, die jeweils mit den neuronalen Netz und STB gefunden wurden und jeweils mit der anderen Auswertungsmethode übereinstimmt, so stellt man fest, dass

$$N_{\text{NN}}/\text{frame} \cdot n_{\text{NN}} \approx N_{\text{STB}}/\text{frame} \cdot n_{\text{STB}} \quad (47)$$

gilt. Dabei ist $N_{\text{NN, STB}}$ die durchschnittliche Anzahl von Teilchen pro frame bei der Auswertung mit dem neuronalen Netz bzw. mit STB ($N_{\text{STB}} = 78,9$) und $n_{\text{NN, STB}}$ der Anteil davon, der einen kleineren Abstand als 0,05 mm zu einem detektierten Teilchen durch STB bzw. mit Auswertung durch ein NN hat. Der Abstand ist in etwa die Länge der Diagonale eines voxels. Auch bei prediction 2 werden trotz der vergleichsweise schlechten Komprimierung der Intensitätsverteilungen der Staubteilchen quasi keine Teilchen, die auch durch STB erkannt wurden, doppelt geortet. Die durchschnittliche Anzahl der Teilchen pro frame stimmt auch etwa mit den maximal 90 Teilchen pro frame in der zweidimensionalen Teilchendetektion vor STB überein. Trotzdem gibt es noch eine sehr große Unregelmäßigkeit beim Training, sodass sich die Trainings nicht wiederholen lassen. Das Hauptproblem scheint die Genauigkeit der initial fields zu sein. Im Vergleich zu den Intensitätsverteilungen der Partikel in [10] sind die Teilchen in den initial fields zu klein und kugelartig. In dem Versuchsaufbau von A. Melzer und M. Himpel stehen die Kameras nicht in einem so großen Winkel zueinander, sodass durch eine Überlagerung der einzelnen Felder der vier Kameras durch die vierte Wurzel die Intensitätsverteilungen der Staubteilchen trotzdem nicht rund, sondern langgestreckt wie eine Zigarre sind. Das initial field ist aber auch nicht so gut, dass direkt die Positionen ausgelesen werden könnten. Bei einem Versuch erkannte das Programm bei einer Erhöhung der nötigen zusammenhängenden Voxels von 7 auf 9 etwa 201,7 Teilchen pro frame. Davon hatten 66,8% einen kleineren Abstand als 0,05 mm zu durch STB erkannten Teilchenpositionen. Das sind fast doppelt so viele, wie eigentlich detektiert werden sollten, was bedeutet, dass sehr viele Teilchen mehrfach gezählt werden. Natürlich lässt sich das Programm zur Teilchendetektion noch genauer einstellen, aber das grundlegende Problem ist, dass die Teilchen im initial field nicht gleich groß sind. Trotz der hohen Genauigkeit des initial fields muss also eine weitere Bearbeitung stattfinden, um die Teilchen auf eine ähnliche Größe zu bringen.

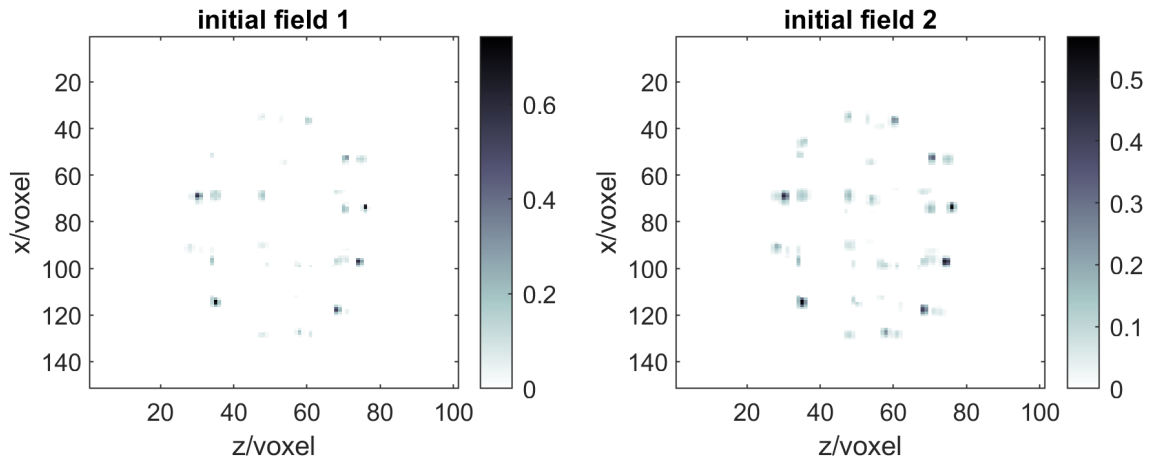


Abbildung 10: Initial fields bei $y = 60$ voxel links mit dem bisherigen Gaußfilter und rechts bei einem vergrößerten Gaußfilter von 5×5 Pixel und einer Varianz von 3 Pixel.

Eine Möglichkeit, die Intensitätsverteilungen noch etwas ungenauer und größer zu gestalten, ist die Veränderung der Parameter im Gaußfilter bei der Aufbereitung der Bilder. So wurde die Varianz auf 3 Pixel und die Größe des Filters auf 5×5 Pixel erhöht. In Abb. 10 sieht man in den initial fields durch diese Änderung eine Vergrößerung der Intensitätsverteilungen der Teilchen von 3-6 voxels auf etwa 5-7 voxels im Durchmesser. Gleichzeitig ist dadurch aber auch eine Absenkung der Intensität der Teilchen zu beobachten.

Mit dem neuen Filter wurden 2000 neue Trainingssets generiert und das Netz mit einem Reduktionsfaktor der Lernrate von 0,1 trainiert. Bei der Auswertung der Messbilder, wurden diese ebenfalls mit dem neuen Filter bearbeitet. Wie man in Abb. 11 sieht, wird die Intensität nicht mehr so stark gesenkt wie bei gleichem Reduktionsfaktor der Lernrate mit dem alten Gaußfilter (siehe Abb. 7). Hierbei sticht aber prediction 4 heraus, in der die Intensität sogar deutlich erhöht wurde und die Intensitätsverteilungen vollkommen verfälscht wurden. Dabei wurden nicht alle Intensitätsverteilungen der Teilchen im initial field gleich stark verfälscht, sondern manche stark vergrößert, während andere ganz verschwinden. Die anderen vier trainierten Netz scheinen aber mit dem neuen initial field besser trainieren zu können. Der Teilchendurchmesser wurde durch jedes von ihnen im prediction field auf etwa 4 voxels reduziert. Trotzdem sieht man bedeutende Unterschiede in den prediction fields. Während das letzte trainierte Netz augenscheinlich sehr viele Partikel verschwinden lässt, so werden durch die ersten drei Netz die Intensitätsverteilungen verschiedener Partikel unterschiedlich stark im Vergleich zu den anderen predictions komprimiert und in ihrer Intensität reguliert.

Die Unterschiede werden wieder bei der Betrachtung der erkannten Teilchenzahlen deutlicher. So zeigt Tab. 4, dass unter den gleichen Standardbedingungen der Teilchenerkennung in prediction 5 nur etwa halb so viele Partikel geortet werden

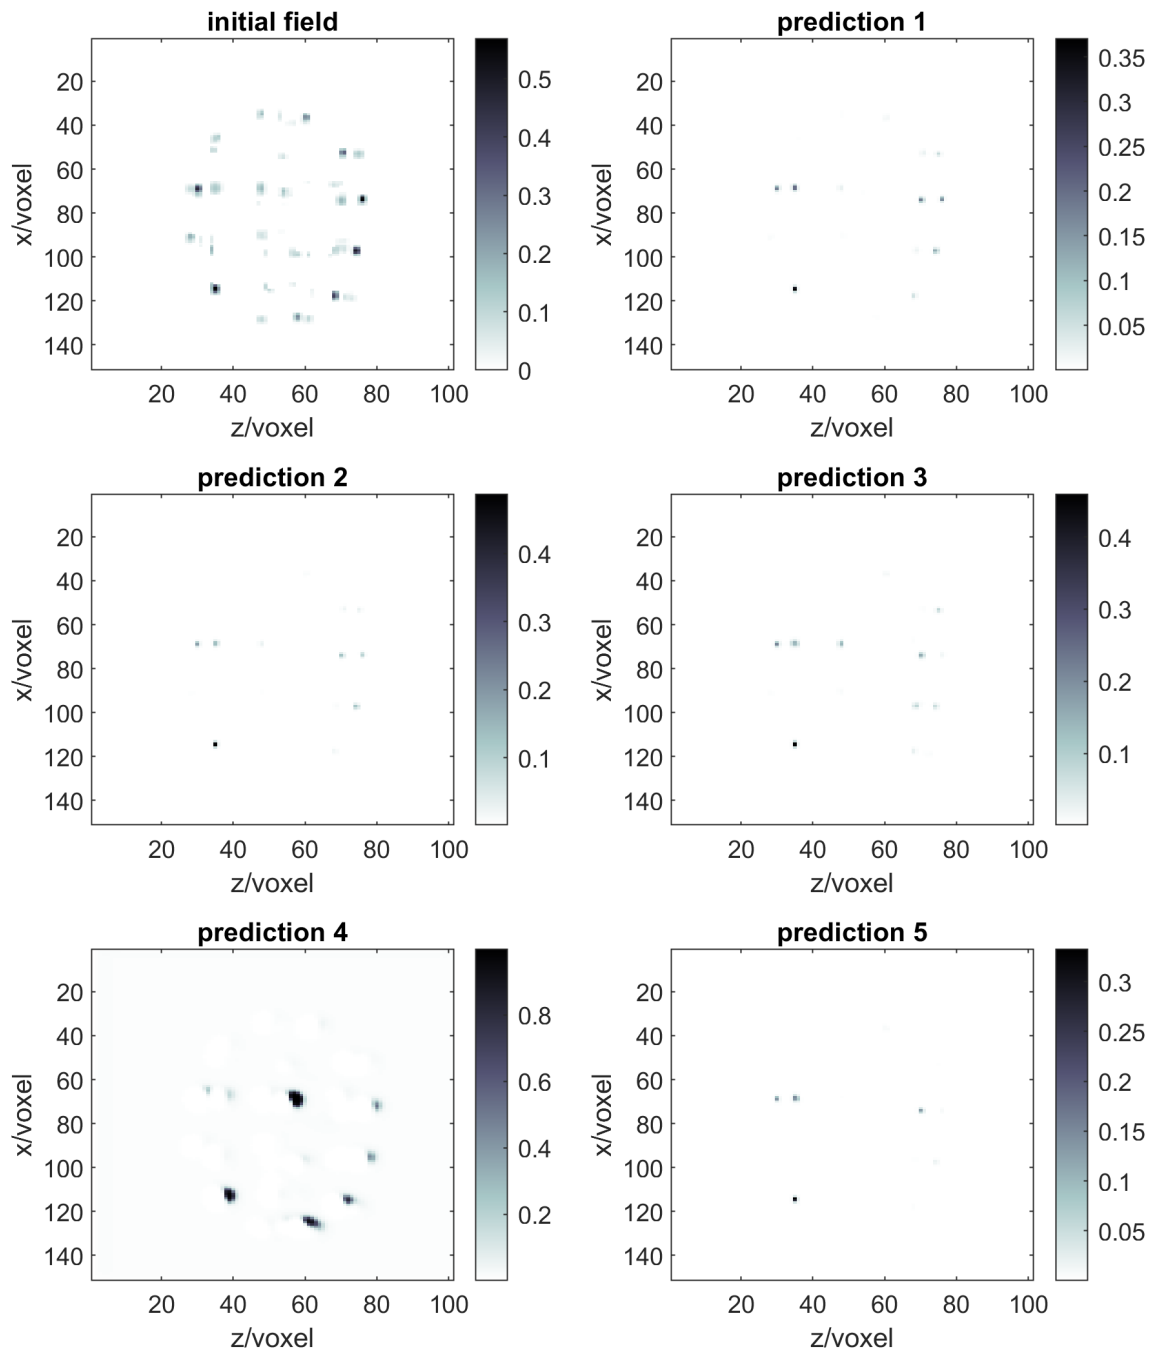


Abbildung 11: Gleicher Ausschnitt im initial field und in den prediction fields wie zuvor. Die predictions stammen von 5, mit den selben Trainingsdaten trainierten, Netzen. Diesmal wurde ein größerer Gaußfilter mit einer Größe von 5×5 Pixel und einer Varianz von 3 Pixel verwendet.

können wie in prediction 3. Die ersten 3 trainierten Netze haben die initial fields so bearbeitet, dass unter diesen Bedingungen zwischen 44 und 48 Teilchen, die auch durch STB erkannt wurden (mit weniger als 0,05mm Abstand), geortet werden konnten. Hingegen konnten in den predictions vom letzten Netz nur durchschnittlich 25 der Teilchen entdeckt werden. Sie alle erfüllen Gl. (47), was zumindest für eine gute Komprimierung und Vereinheitlichung der Intensitätsverteilungen spricht, dennoch gibt es offenbar noch große Unterschiede im Training, was vor allem durch prediction 4 verdeutlicht wird.

Tabelle 4: Die Teilchenzahlen wurden unter Nutzung der Parameter zur Teilchenerkennung wie zuvor erfasst. Da unter diesen Bedingungen keine sinnvolle Auswertungen der predictions vom 4. trainierten Netz möglich war, wurde diese hier nicht berücksichtigt.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	51,9	85,8	56,2
2	50,3	92,7	59,1
3	63,0	76,6	61,0
5	29,0	86,6	31,7

Eine Verringerung des Reduktionsfaktors der Lernrate auf 0,05 mit 2000 neuen Trainingsdatensätze und dem neuen Gaußfilter führt, wie in Tab. 5 zu sehen ist, auch zu keinem stabileren Trainingsprozess. Die Anzahl der erkannten Teilchen variiert nur noch mehr als zuvor, wobei das letzte Netz die Intensitäten wieder so stark abgesenkt hat, dass keine Teilchen mehr zu erkennen waren.

Tabelle 5: Die Teilchenzahlen wurden unter Nutzung der Standardparametern zur Teilchenerkennung wie zuvor erfasst. Die Netze wurden analog zu den Netzen in Tab. 4 trainiert, aber mit reduziertem learn rate drop factor von 0,05.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	73,2	94,8	87,8
2	82,0	89,0	92,2
3	38,8	91,4	44,8
4	33,9	84,8	36,3
5	0	0	0

4.3 Berechnung der initial fields mittels des Durchschnitts

Eine andere Möglichkeit die Intensitätsverteilungen der einzelnen Partikel zu vergrößern oder zu verzerren, ist die Änderung der Berechnung des initial field. Die Verwendung des Durchschnitts anstatt der vierten Wurzel führt zu einer deutlichen Veränderung. In Abb. 12 ist oben links das neue initial field zu sehen. Die Intensitätsverteilungen nehmen ein Streifenmuster an, das sich überkreuzt. Dabei liegt

die Intensität der mutmaßlichen Teilchen in den Kreuzungen der Streifen zwischen 0,23 und 0,7, wobei die Streifen bereits eine Intensität von bis zu etwa 0,19 besitzen. Somit gibt es keinen großen Unterschied in der Intensität zwischen Teilchen und Streifen, was es für das Netzwerk schwer machen wird, die Teilchen zu isolieren.

Im ersten Versuch wurde wieder wie auch zuvor bei der vierten Wurzel das Programm fünf mal mit den selben 2000 Trainingsdatensätzen wie auch in den vorherigen 5er-Wiederholungen trainiert. lediglich die initial fields mussten neu berechnet werden. Der learn rate drop factor betrug zuerst 0,1, wobei sich in Abb. 12 zeigt, dass das Netzwerk wieder sehr unregelmäßig trainiert. Auffällig ist, dass das Netzwerk die Streifen nicht herausgefiltert bekommt. Manchmal sind sie im prediction field mehr und manchmal weniger stark ausgeprägt. Das ist problematisch, da die Intensität gesenkt wird und dadurch nicht mehr gut zwischen echten Teilchen und restlicher Intensitätsverteilung unterschieden werden kann. Das wird vor allem in prediction 5 deutlich. Lässt man zur Probe einmal standardmäßig das Positionserkennungsprogramm im Intensitätsintervall von 0,7 bis 0,05 mit einer Schrittweite von 0,005 bei mindestens sieben kompakt zusammenhängende voxels laufen, so zeigt sich, dass das Programm mit dem Erkennen der Partikel Probleme hat.

Tabelle 6: Anzahlen der durchschnittlich erkannten Teilchen pro frame unter Nutzung des Durchschnitts zur Berechnung des initial fields bei einem learn drop rate factor von 0,1.

Durchlauf	N_{NN}
1	3,3
2	0,4
3	2,2
4	9,2
5	3,2

Wie also in Tab. 6 zu sehen ist, konnte das Programm durch die geringe Intensität der Teilchen wieder nur wenige Partikel erkennen. Eine Reduktion des Schwellwertes der Intensität bei der Partikelerkennung führt aber zu vermehrter Fehlerkennung von Teilchen, da der Unterschied zwischen den Intensitäten der echten Teilchen und der Streifen zu gering ist. In prediction 5 beispielsweise liegt die Intensität der verbleibenden Streifen im Bereich von 0,0006 bis 0,013, während die potentiellen Teilchen eine Intensität zwischen 0,016 und 0,127 besitzen. Daher lässt sich die untere Grenze des Intensitätsintervalls, in dem Partikel gesucht werden sollen, nicht sinnvoll einstellen ohne zu viele Ghostpartikel zu zählen oder zu viele reale Partikel rauszufiltern. Außerdem schaffen es die trainierten Netzwerke nicht die Teilchen in ihrer Kugelgestalt zu komprimieren und auf vergleichbare Größe zu bringen. So variiert der Durchmesser der Teilchen in allen prediction fields zwischen 4 und 8 voxels.

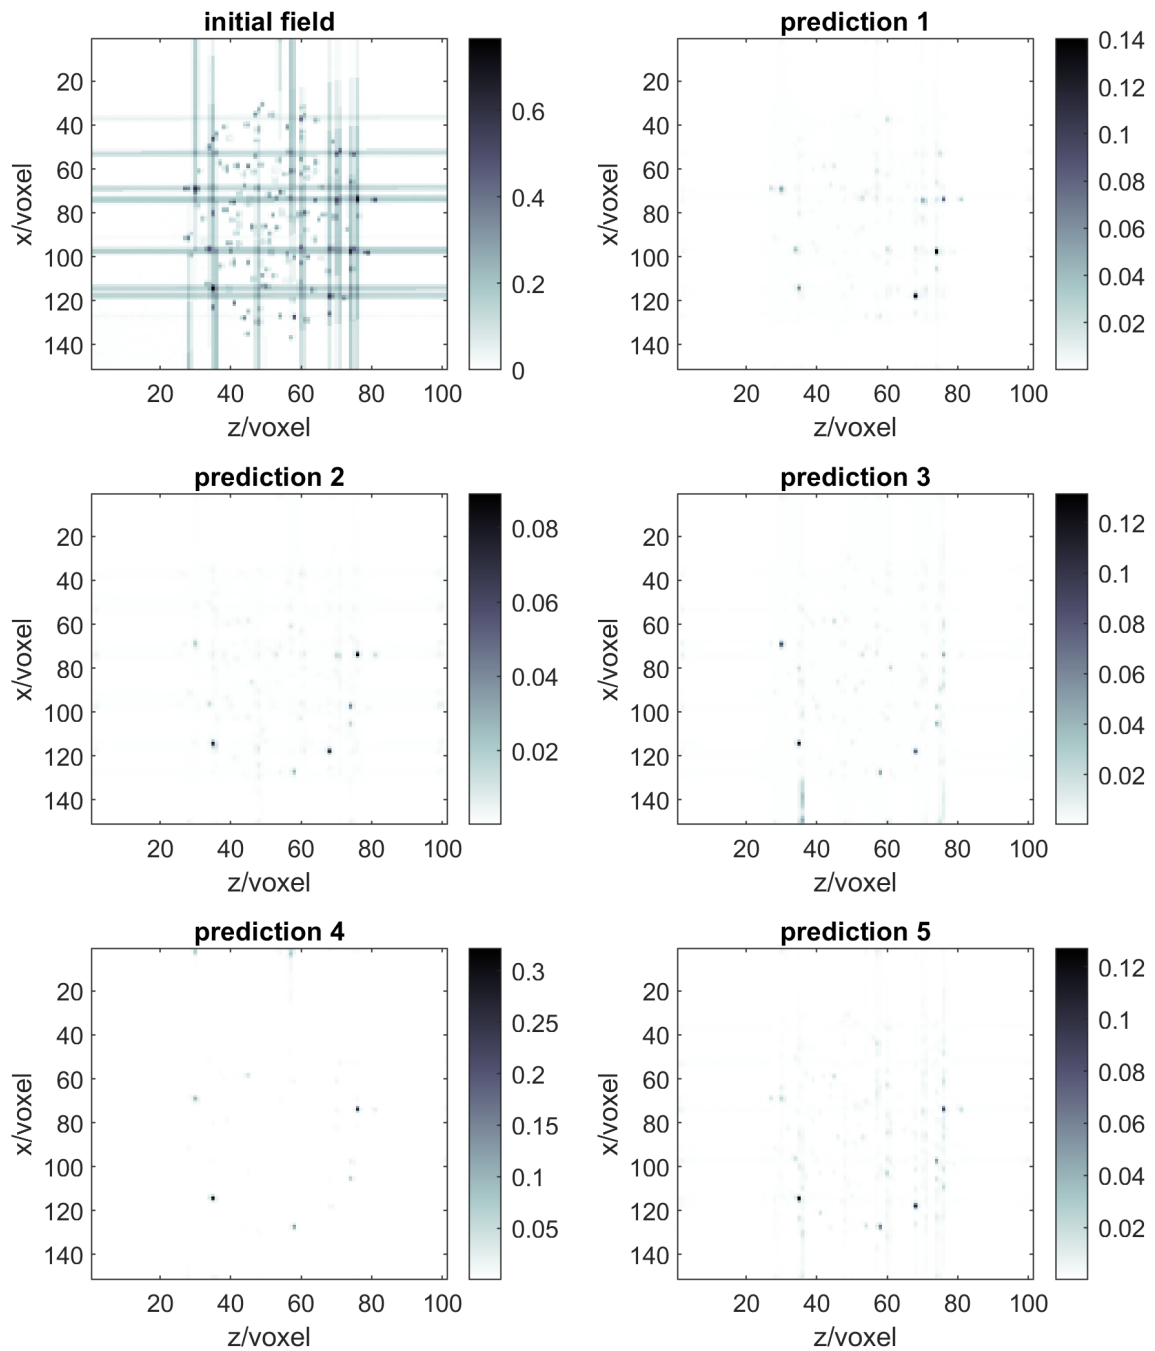


Abbildung 12: Alle Ausschnitte sind aus dem selben frame wie zuvor und bei $y = 60$ voxel. Oben links ist das neue initial field zu sehen. Das Netzwerk wurde wiederholt 5 mal mit den selben Trainingsset bei einem learn drop rate factor von 0,1 trainiert.

Um die Ergebnisse des Trainings zumindest vergleichbarer zu machen, wurde das Training wieder mit einem learn rate drop factor von 0,05 wiederholt. Wie in Abb. 13 zu sehen ist, wird die Intensität von den trainierten Netzen ähnlich stark herabgesenkt wie zuvor und gerade in der Mitte, wo die größte reale Teilchendichte ist, schaffen es die Netze wieder nicht die Intensität der Teilchen gut genug zu komprimieren und die Streifen herauszufiltern. Das neuronale Netz mit diesem Design scheint also von der hohen Intensitätsverteilung überfordert zu sein, sodass es mit der Anzahl an layer und den enthaltenen convolution filter nicht lernen kann die verzerrten Intensitätsverteilungen der Partikel zu komprimieren. Dies führt auch wieder dazu, dass zu viele voxels mit hoher Intensität übrig bleiben, die vom Positionskonstruktionsprogramm als potentielle Teilchen erkannt werden können. So variiert unter gleichen Bedingungen der Positionserkennung wie zuvor die durchschnittliche Anzahl der erkannten Teilchen pro frame stark, wie es in Tab. 7 zu sehen ist. Vergleicht man die Bilder der predictions mit der Anzahl der erkannten Teilchen pro frame, so bestätigt sich, dass gerade die letzten drei Trainingsdurchläufe mit der schlechtesten Filterung der Streifen aus dem initial field auch die meisten Teilchen liefern. Trotzdem stimmen im Durchschnitt über alle frames etwa 82,2% der erkannten Positionen in prediction 3 mit den Positionen aus STB überein, was daran liegt, dass die untere Intensitätsschwelle zur Teilchenerkennung mit 0,05 deutlich über der Intensität der Streifen liegt. In diesem Fall macht sich also die Vergrößerung der Teilchen im initial field durch Berechnung mittels des Durchschnitts positiv bemerkbar. Trotzdem sind die Streifen immer noch ein potentieller Störfaktor bei der Teilchenerkennung.

Tabelle 7: Durchschnittliche Anzahlen der Teilchen pro frame zu den Netzen aus Abb. 13 unter den gleichen zuvor genutzten Standardbedingungen zur Teilchenerkennung.

Durchlauf	N_{NN}
1	2,4
2	0,5
3	38,1
4	12,7
5	24,7

Um dem Netzwerk mehr Trainingsdurchläufe zu geben, aber dabei die Wahrscheinlichkeit einer Überanpassung gering zu halten, wurde ein weiterer Trainingsdurchlauf mit 3000 neuen Trainingssets mit einem Reduktionsfaktor der Lernrate von 0,1 gemacht. Eine Erhöhung der Trainingssets könnte dem Netzwerk mehr Daten geben um zu lernen die Streifen von den Partikeln zu unterscheiden. Wie sich aber in Abb. 14 zeigt, senkt das trainierte Netz die Intensität wieder zu stark herab, sodass eine sinnvolle Positionserkennung nicht möglich ist. Dies bestätigt nur wieder, dass die Intensitätsverteilung bei der Überlagerung der einzelnen Felder mittels des Durchschnitts zu groß und verzerrt ist.

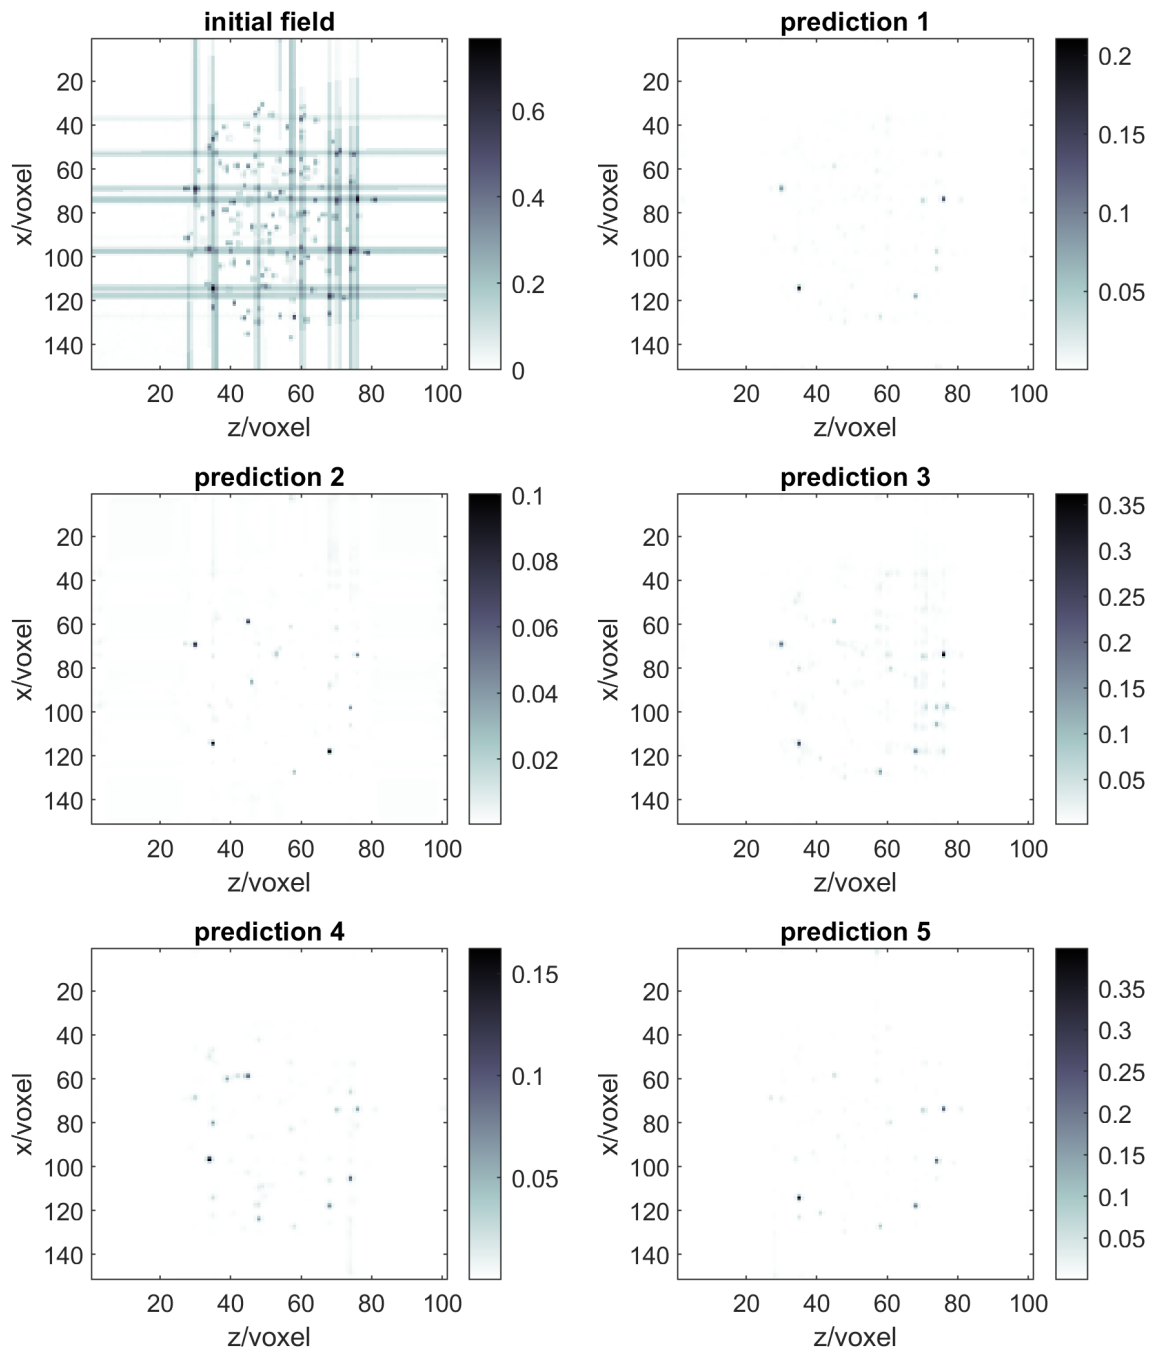


Abbildung 13: Gleicher frame und Ausschnitt bei $y = 60$ voxel. Die predictions stammen von neuronalen Netzen, die mit dem selben Trainingsset wie zuvor und einem learn drop rate factor von 0,05 trainiert wurden.




Abbildung 14: Ausschnitt aus dem initial field und dem prediction field im selben frame wie zuvor bei $y = 60$ voxel. Das Neuronale Netz wurde mit 3000 neuen Trainingssets bei einem learn drop factor von 0,1 trainiert.

Zuletzt wurden 1200 neue Trainingssets erstellt und das neuronale Netz zweimal mit den selben Trainingsdaten bei einem learn rate drop factor von 0,05 trainiert. Wie aber in Abb. 15 in den prediction fields zu erkennen ist, hat sich das nicht bestätigt. Zu wenig Trainingsdurchläufe führen auch nur dazu, dass das Netz dazu tendiert allgemein die Intensität in allen voxels zu senken. Außerdem scheint das neuronale Netz sehr unterschiedlich bei den gleichen Trainingsdaten zu trainieren. Das Netzwerk kann also keine sinnvollen Parameter in den convolutional filter und Bias finden um die Teilchen zu komprimieren. Bei der Größe und Verzerrung der Intensitätsverteilungen der Teilchen müsste das Netzwerk auch eigentlich lernen die Streifen ganz herauszufiltern, wobei es in diesem Fall aber immer auch die Intensität der Teilchen zu stark reduziert.

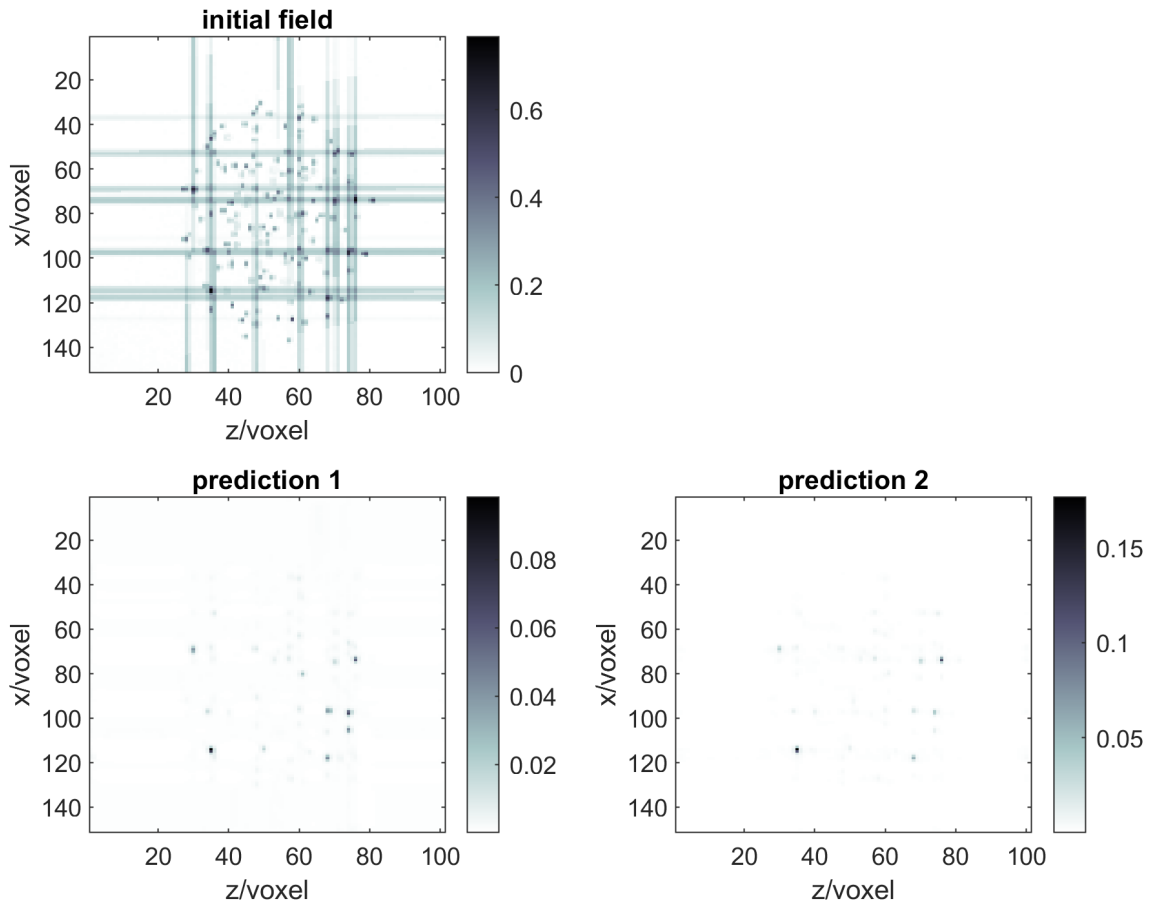


Abbildung 15: Ausschnitt an der gleichen Stelle wie zuvor. Das Netz wurde 2 mal mit den selben 1200 neuen Trainingssets bei einer Reduktionsfaktor der Lernrate von 0,05 trainiert.

4.4 Durchschnitt der beiden bisherigen initial fields als neues initial field

Als schnelle und einfache Möglichkeit die Probleme beider vorherigen Ansätze lösen zu können, wurde wie in Gl. (45) der Durchschnitt der beiden vorherigen initial fields verwendet. Das neue initial field ist nicht mehr so genau wie das, welches mit der vierten Wurzel überlagert wurde. Auch ist die Intensität der Streifen im Vergleich zu den Teilchenintensitäten kleiner als in den letzten initial fields. Im ersten Versuch wurde das neuronale Netz drei mal wieder bei einem learn rate drop factor von 0,1 mit den Gleichen 2000 Trainingsdaten wie bei den vorherigen 5er-Reihen trainiert. Die initial fields wurden gemäß Gl. (45) neu berechnet. Die prediction fields in Abb. 16 zeigen, dass das Netzwerk mit den neuen initial fields besser lernen kann.

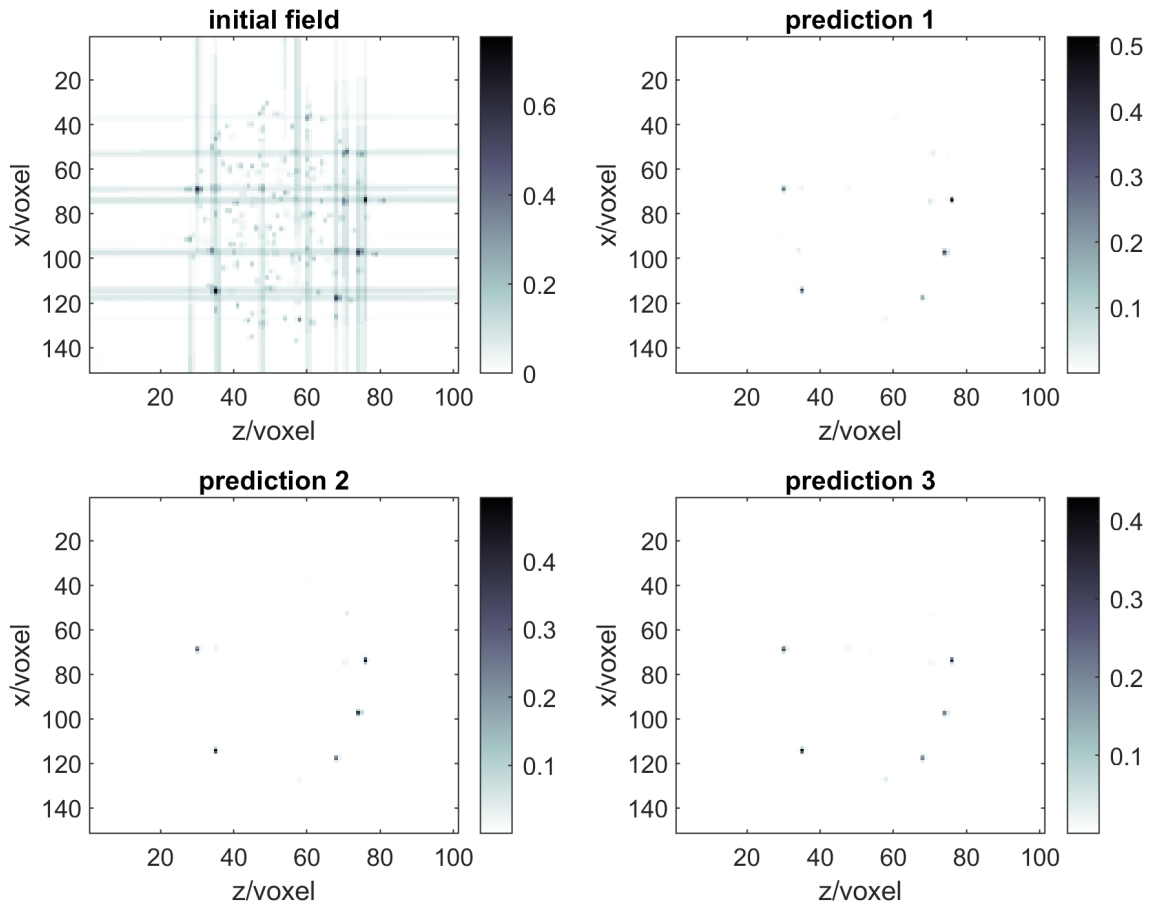


Abbildung 16: Die Ausschnitte stammen aus dem gleichen frame wie in allen anderen Bildern und bei $y = 60$ voxel. Hier wurde das Netz 3 mal mit den gleichen Trainingssets und Trainingsbedingungen wie in Abb. 12 trainiert. Diesmal wurde das initial field mittels Gl. (45) berechnet.

In allen drei predictions haben es die trainierten Netze geschafft die Streifen fast völlig herauszufiltern und dabei die maximale Intensität nicht zu sehr abzusenkten. Die Intensität der Streifen liegt maximal bei etwa 0,08, während die voxels im Zentrum einer Intensitätsverteilung eines vermeintlichen Staubteilchens meist mindestens eine Intensität von 0,2 besitzen. Das Training des Netzes mit der neuen Berechnungsmethode des initial field führt zu stabileren Ergebnissen beim Training mit den selben Trainingsdaten. Die Größe der Teilchen wird auch mit allen drei trainierten Netzen auf etwa 6 voxels reduziert, während die Größe im initial field sehr unregelmäßig und schwer zu erkennen ist. Die Intensitätsdifferenz zwischen den Streifen und den Partikeln ist im initial field also groß genug, dass das neuronale Netz lernen kann die Teilchen auf eine etwa einheitliche Größe zu komprimieren und dabei recht vergleichbare Ergebnisse zu erzielen. Schaut man sich die Anzahlen der rekonstruierten Teilchen an (siehe Tab. 8), so fällt auf, dass diese ziemlich konstant sind, auch wenn sie noch etwas von den durchschnittlichen 78,9 Teilchen

pro frame aus STB entfernt sind. Betrachtet man wieder die absolute Anzahl der Teilchen, die mit der jeweiligen anderen Auswertungsmethode überein stimmen, so sieht man, dass wieder Gl. (47) für alle predictions erfüllt ist. Somit werden nach der Auswertung mit diesen neuronalen Netzen weniger Teilchen erkannt als mit STB, aber diese stimmen fast vollständig mit den Teilchen überein, die auch mit STB erkannt wurden, wobei auch kaum Teilchen doppelt gezählt werden. Diese kleinen Abweichungen können jedoch gut damit erklärt werden, dass STB einige Teilchen aussortiert, die nicht in genügend Kameras und frames erkannt werden.

Tabelle 8: Teilchenmanzahlen mit den Anteilen der übereinstimmenden Teilchen, die auch mit der jeweiligen anderen Auswertungsmethode entdeckt wurden, für die Netzwerke aus Abb. 16.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	62,1	98,1	77,2
2	52,6	97,9	65,3
3	49,5	97,4	61,2

Eine Reduktion der unteren Intensitätsschwelle bei der Teilchenerkennung auf 0,02 führt bereits zu einer starken Zunahme der erkannten Teilchenanzahl, was aber auch auf eine vermehrte Erkennung von vermeintlichen Ghostteilchen zurück zu führen ist.

Tabelle 9: Gleiche Netzwerke wie in Tab. 8, nur mit abgesenkter unterer Intensitätsschwelle von 0,02.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	117,6	91,0	98,7
2	101,4	93,1	93,1
3	104,4	92,1	95,5

Wie man in Tab. 9 sieht, werden jedoch die meisten Partikel erkannt, die auch mit STB erkannt wurden. Bei der Betrachtung von Gl. (47) fällt auf, dass etwa 20, bei dem ersten trainierten Netz sogar 30, Teilchen doppelt erkannt werden, die durch STB nur einmal geortet wurden. Eine Erhöhung der Mindestanzahl der zusammenhängenden voxels führt bei niedriger Intensitätsschwelle zur starken Verringerung des Anteils der richtig erkannten Teilchen. Die Anwendung der trainierten Netze lässt somit trotzdem noch einige Teilchen verschwinden. Entweder wird ihre Intensität zu sehr gesenkt oder sie werden zu klein.

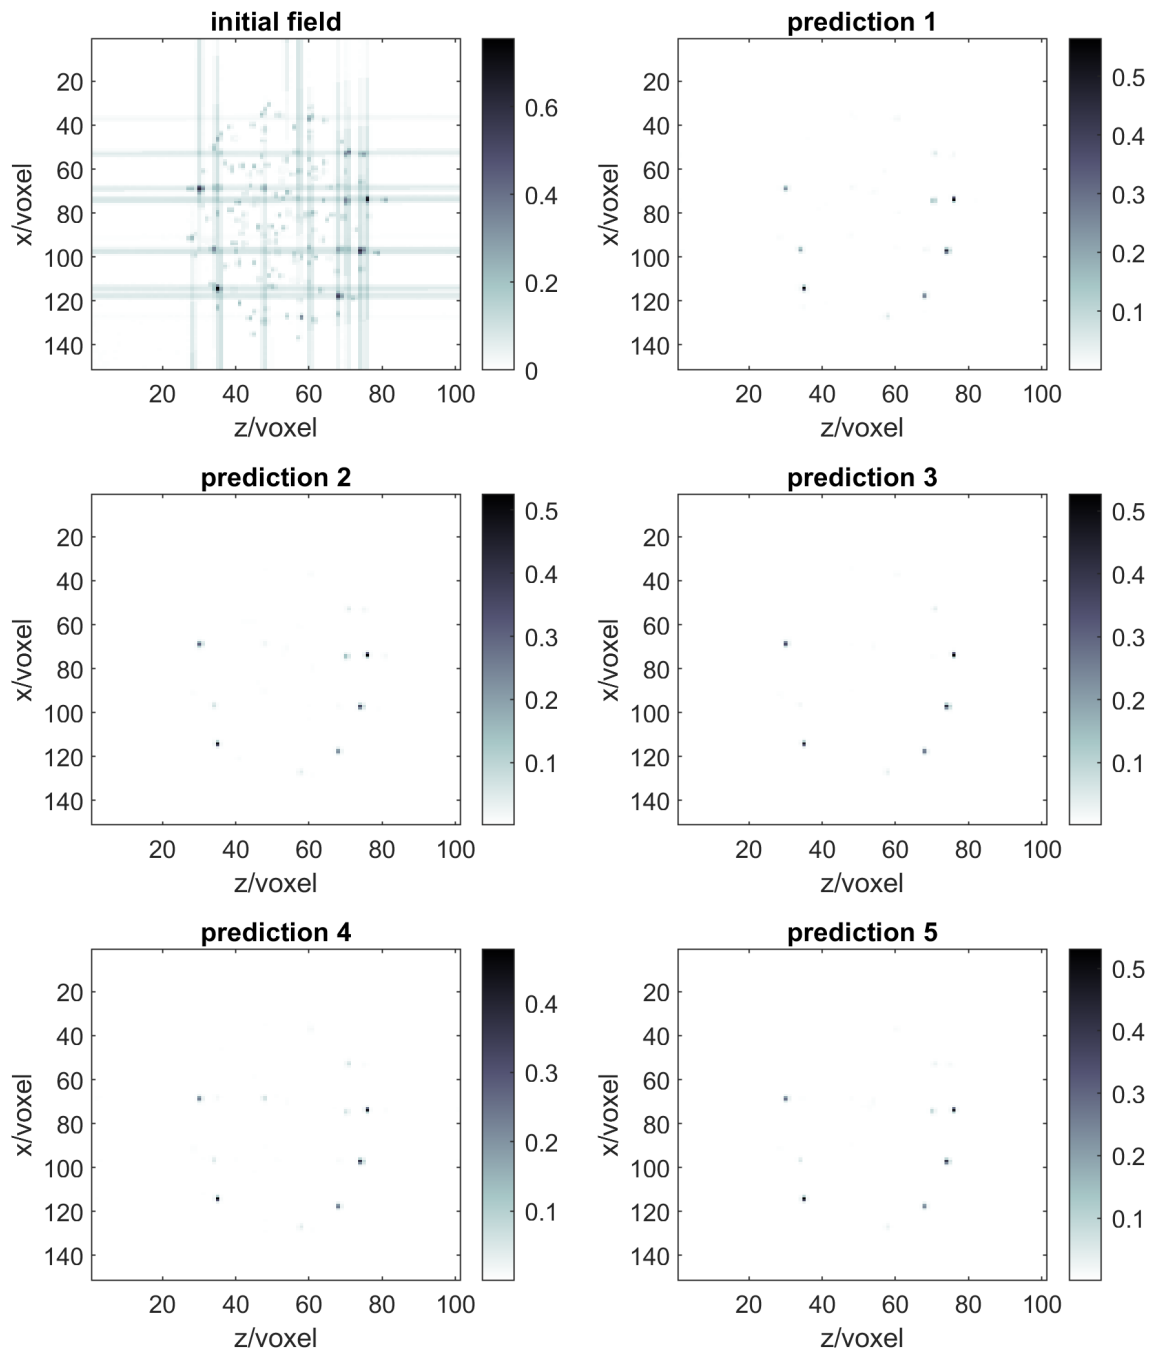


Abbildung 17: Gleicher Ausschnitt aus den fiels wie zuvor. Trainiert wurde zuerst 3 mal mit den gleichen Trainingsdaten wie in Abb. 16 bei einem learn rate drop factor von 0,05 und danach 2 weitere Male unter gleichen Bedingungen mit 2000 neuen Trainingssets.

Eine Reduktion des learn rate drop faktor auf 0,05 bei sonst gleichen Trainingsbedingungen und -daten führt, wie bei den prediction fields 1 bis 3 in Abb. 17 zu sehen ist, nur zu einer leichten Verbesserung der Reproduzierbarkeit der Ergebnisse. Es zeigt sich aber, dass bei Wiederholung des Trainings mit neuen Trainingsdaten (predictions 4 und 5) die trainierten Netze vergleichbare Ergebnisse liefern wie bei den vorherigen Trainingsdatensätze. Somit scheint das Training mit dem kleineren learn rate drop factor zu stabileren Ergebnissen zu führen. Betrachtet man wieder die durchschnittliche Anzahl der erkannten Teilchen pro frame bei einer Mindestintensität von 0,05 (siehe Tab. 7), dann sieht man, dass die Zahlen nah bei der durch STB erkannten Teilchenzahl liegen. Die Varianz der Teilchenzahl bei den ersten drei trainierten Netzen mit den gleichen Trainingsdaten ist etwa vergleichbar mit den drei trainierten Netzen mit einem learn rate drop factor von 0,1. Bei den wenigen Trainingsdurchläufen lässt sich das aber nicht genauer untersuchen, da es wie in Abb. 11 immer Ausreißer geben könnte.

Tabelle 10: Erkannte Teilchenzahlen mit den jeweiligen Anteilen, die mit den Teilchenpositionen übereinstimmen, die mit der jeweils anderen Auswertungsmethode erkannt wurden. Die ausgewerteten predictions sind in Abb. 17 beispielhaft gezeigt.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	78,8	93,4	93,0
2	74,3	95,3	89,7
3	65,2	98,0	81,0
4	61,8	98,0	76,8
5	65,9	97,5	81,4

Ebenfalls ist wie zuvor auch bei einer Mindestintensität von 0,05 Gl. (47) erfüllt. Somit sind die Ergebnisse bei Wiederholung des Trainings nicht signifikant stabiler geworden, jedoch stimmen sie bei einem learn drop factor von 0,05 eher mit den Ergebnissen von STB überein. Außerdem führt auch das Training mit neuen Trainingsdaten zu stabilen Ergebnissen (vgl. Durchlauf 4 und 5 zu 1, 2 und 3 in Tab. 7), im Gegensatz zum Training des neuronalen Netzes bei Nutzung der Wurzel oder des Durchschnitts zur Berechnung des initial field.

5 Auswertung der zweiten Messung

5.1 Erstellung der Trainingssets

Da sich die Messbilder in der Helligkeit, Größe und Position der Teilchen zu den Vorherigen unterschieden, mussten die Parameter bei der Generierung der Trainingssets abgeändert werden. Diesmal wurden 180 Teilchen in dem Volumen generiert, da dieses kleiner ist als zuvor. Das Gebiet von $-1,5 \text{ mm} \leq x \leq 1 \text{ mm}$, $-0,7 \text{ mm} \leq y \leq 1,3 \text{ mm}$ und $580,8 \text{ mm} \leq z \leq 583 \text{ mm}$ wurde in ein $125 \times 100 \times 55$ voxel großes Gitter

unterteilt. Die voxels haben dabei die gleiche Größe von $0,02\text{ mm} \times 0,02\text{ mm} \times 0,04\text{ mm}$ wie zuvor. Für die Bilder wurde ein zufälliger Vorfaktor vor der Normalverteilung der Intensität zwischen 102 und 255 Graustufen (in der auf Eins normierten Intensitätsskala: 0,4-1) für jede generierte Position berechnet. Die Varianz beträgt 1,1 Pixel. Alle Bilder besitzen vorab wieder eine Grundintensität von 1,785 Graustufen. Die Bilder werden anschließend von den beiden Sobelfiltern bearbeitet. Der Gaußfilter wurde wegen der höheren Intensität und Größe der Teilchen auf 5×5 Pixel mit einer Varianz von 3 Pixeln vergrößert. Anschließend werden die Bilder wieder auf maximal 255 Graustufen normiert, da die Intensität durch die Filter und die höhere Intensität der Teilchen auf den Bildern teilweise deutlich darüber liegt. Die Berechnung der initial field erfolgt nach Gl. (45), wobei wieder ein Rauschen zwischen 0 und 7,65 Graustufen dem initial field zugefügt werden.

Die Generierung der training fields erfolgt analog zur ersten Messung. Der Vorfaktor der Normalverteilung ist diesmal mit dem bei den Bildern identisch. Die Varianz der Normalverteilung wird variiert und beträgt zuerst $20\mu\text{m}$ und später wieder $15\mu\text{m}$.

5.2 Training mit größeren Intensitätsverteilungen im training field

Bei dem ersten Versuch mit den neuen Messdaten wurde die Teilchengröße im training field im Vergleich zu denen bei der Auswertung der ersten Messung vergrößert, da die Partikel auf den Bildern auch größer sind als zuvor. Trainiert wurde 5 mal mit den selben 2000 Trainingssets in 3 Epochen bei einem learn rate drop factor von 0,1. Wie man in Abb. 18 in den Ausschnitten aus den prediction fields sehen kann, ähneln sich die Netze in der Auswertung der Bilder sehr stark. Die maximale Intensität schwankt nur leicht zwischen den verschiedenen Trainingsdurchläufen und die Intensitätsverteilungen der Teilchen werden auch gleich gut komprimiert. Während im initial field die Intensitätsverteilungen der Teilchen noch einen erkennbaren Durchmesser von etwa 4-5 voxels mit zusätzlichen Streifen haben, sind die Intensitätsverteilungen in den prediction fields nur noch 4 voxels im Durchmesser groß und besitzen eine Intensität von mindestens 0,3, wodurch sie sich deutlich von der Umgebung abgrenzen. Die Streifen, die im initial field eine Intensität von bis zu 0,13 besitzen, sind in den predictions ähnlich wie in Abb. 16 nicht mehr zu erkennen.

Betrachtet man wieder die durchschnittliche Anzahl der georteten Teilchen pro frame aus Tab. 11, bestätigt sich, dass die trainierten Netze in der Auswertung sehr ähnlich sind.

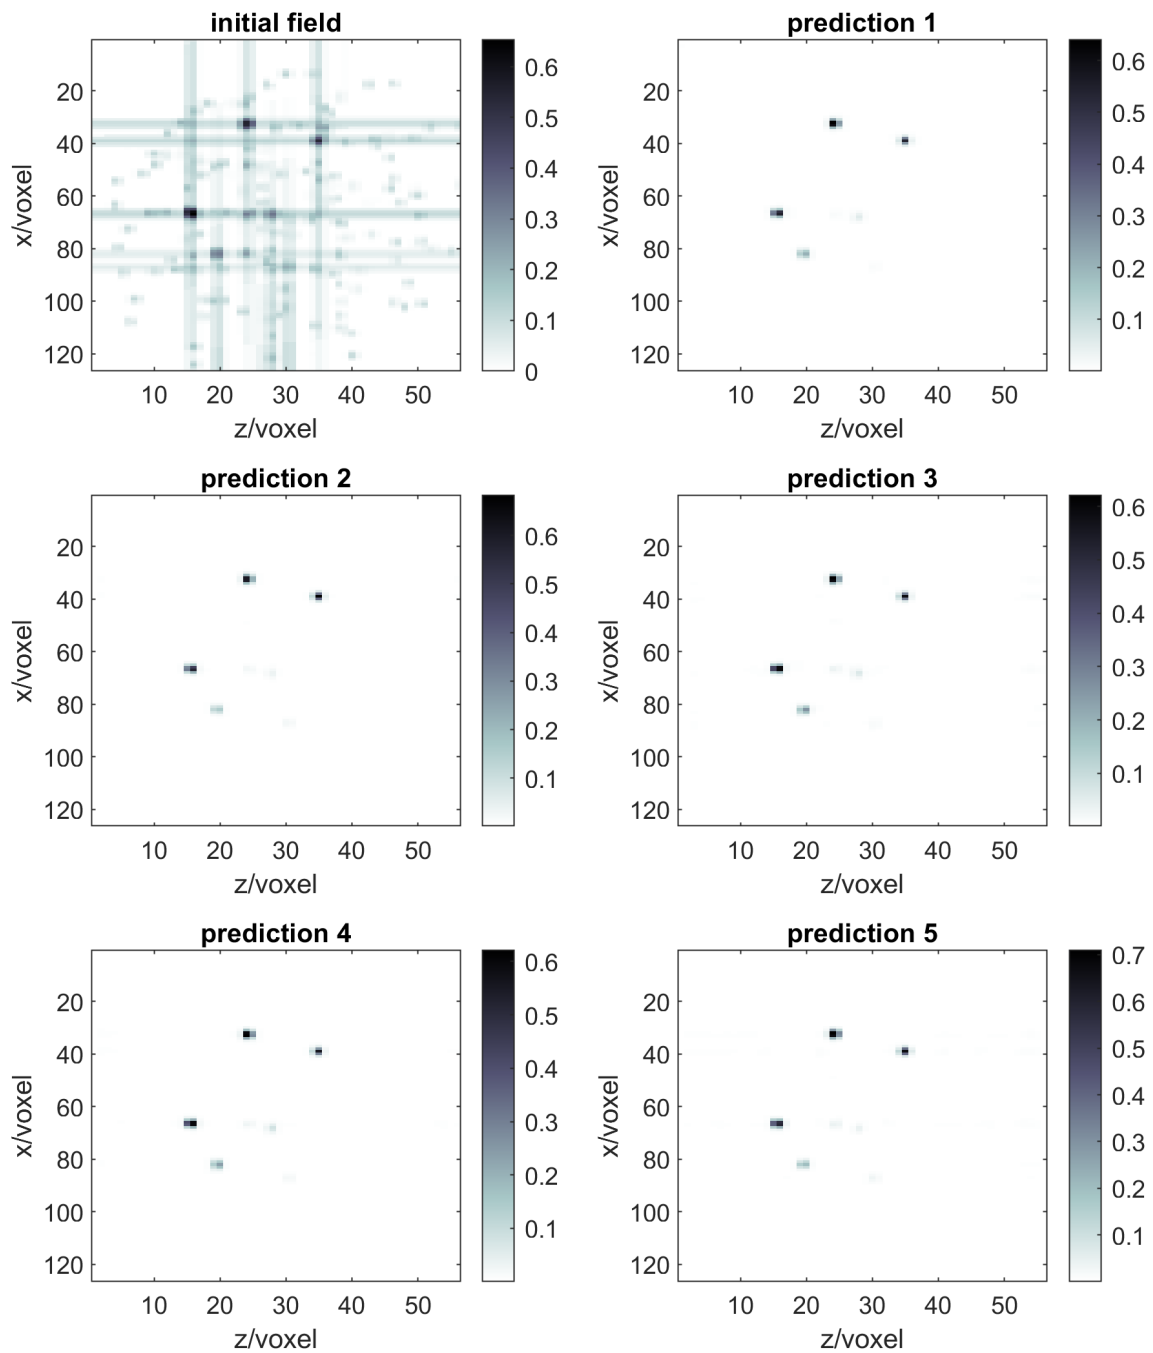


Abbildung 18: Das initial field und die predictions von 5 gleich trainierten Netzen mit den selben Trainingssets bei größeren Partikeln im training field ($20 \mu\text{m}$ Varianz der Normalverteilung). Der Ausschnitt ist bei $y = 75$ voxel.

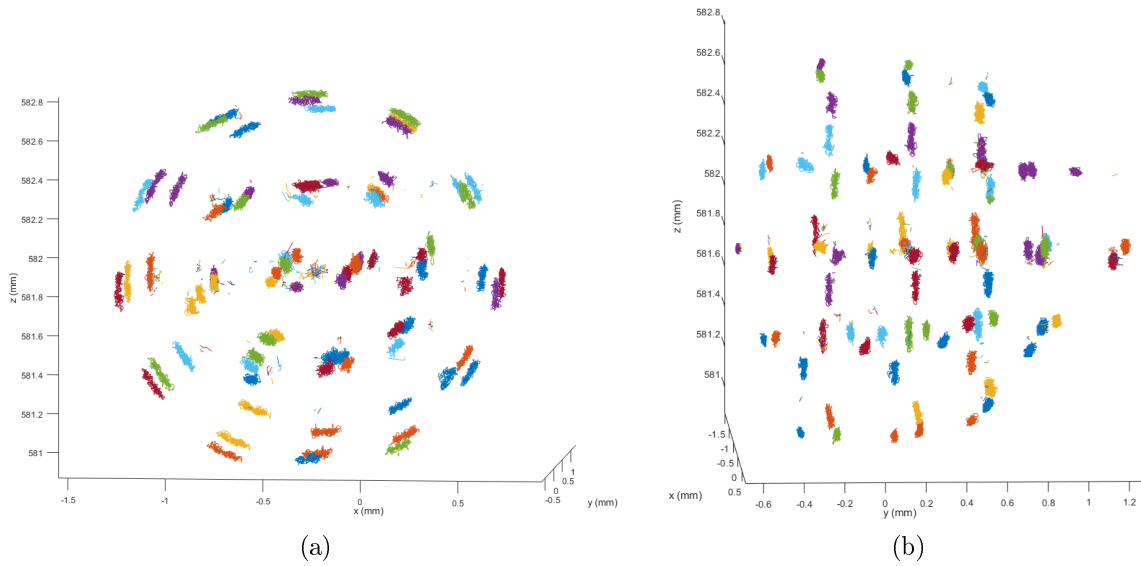


Abbildung 19: Die Teilchentrajektorien aus der Auswertung mittels STB. Die Form des Clusters und die Anzahl der Teilchen sind dem Cluster aus Abb.6 sehr ähnlich.

Tabelle 11: Anzahl der durchschnittlich von den 5 trainierten Netzen aus Abb. 18 georteten Teilchen. Als Teilchen wurden 11 kompakte voxels mit einer schrittweisen Absenkung der Intensitätsschwelle von 0,7 bis 0,1 bei einer Schrittweite von 0,005 gezählt.

Durchlauf	N_{NN}
1	58,6
2	57,1
3	61,5
4	61,1
5	65,2

Um die Qualität der Auswertungen der trainierten Netze etwas einschätzen zu können, wurde wieder eine Auswertung mit STB zum Vergleich herangezogen (siehe Abb. 19). Vergleicht man den Anteil der Teilchen, die einen Abstand kleiner als 0,05 mm zu Teilchen der STB-Auswertung haben (siehe Tab. 12), dann fällt auf, dass wieder nur zwischen 69-77% der Teilchen von STB erkannt werden (vgl. Tab. 8), Tendenz fallend. Da einige Teilchen aus der Auswertung mit STB nach der Bearbeitung des initial field mit dem neuronalen Netz doppelt gezählt werden, müsste die Anzahl der voxels, die als Partikel erkannt werden sollen, noch leicht angehoben werden. Dadurch würden auch wieder einige der „richtigen“ Teilchen wegfallen. Nichts desto trotz ist der erkannte Anteil der Teilchen, die auch mit STB erkannt wurden, ziemlich stabil.

Tabelle 12: Erweiterung zu Tab. 11. Anteile der Teilchen, die einen Abstand kleiner als 0,05 mm zu erkannten Positionen durch die jeweils andere Auswertungsmethode haben.

Durchlauf	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	99,9	70,8
2	99,9	69,9
3	99,8	75,2
4	99,9	74,7
5	99,8	76,8

5.3 Training bei Reduzierter Größe der Partikel im training field

Verringert man die Größe der Partikel im training field auf die gleiche Größe wie bei den Trainingsdaten der ersten Messung, so werden die Intensitätsverteilungen der Partikel auch deutlich stärker komprimiert. In Abb. 20 sieht man die Ausschnitte aus den prediction fields, wobei das Netz wieder 5 mal mit dem selben, neu erstellten Trainingsset trainiert wurde. Alle trainierten Netze komprimieren die Intensitätsverteilungen der Partikel auf einen Kern mit etwa 3 voxel im Durchmesser, der sich mit einer Mindestintensität von 0,1 deutlich von der Umgebung unterscheidet. Lediglich die prediction 4 fällt auf, da das trainierte Netz die Intensität im gesamten initial field deutlich mehr absenkt als alle anderen.

Bei der Auswertung der prediction fields mit dem Positionserkennungsprogramm fallen auch größere Schwankungen sowohl bei der Teilchenzahl als auch bei den Anteilen übereinstimmender Teilchen als in Tab. 12 auf. In den prediction fields des vierten trainierten Netzes werden deutlich weniger Partikel geortet als in den prediction fields der anderen trainierten Netze. Das ist auf die stärker reduzierte Intensität der Teilchen zurückzuführen.

Tabelle 13: Anzahl der erkannten Teilchenpositionen sowie der Anteil, der jeweils mit den Positionen der anderen Auswertungsmethode übereinstimmt. Als Teilchen wurden mindestens 5 kompakt zusammenhängende voxels im Intensitätsintervall zwischen 0,7 und 0,1 gezählt. Als übereinstimmende Teilchenpositionen wurden solche gezählt, die einen Abstand kleiner als 0,05 mm zueinander haben.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	59,9	99,8	74,7
2	63,2	99,7	78,3
3	59,1	99,7	73,6
4	49,8	99,9	62,4
5	60,3	99,8	75,0

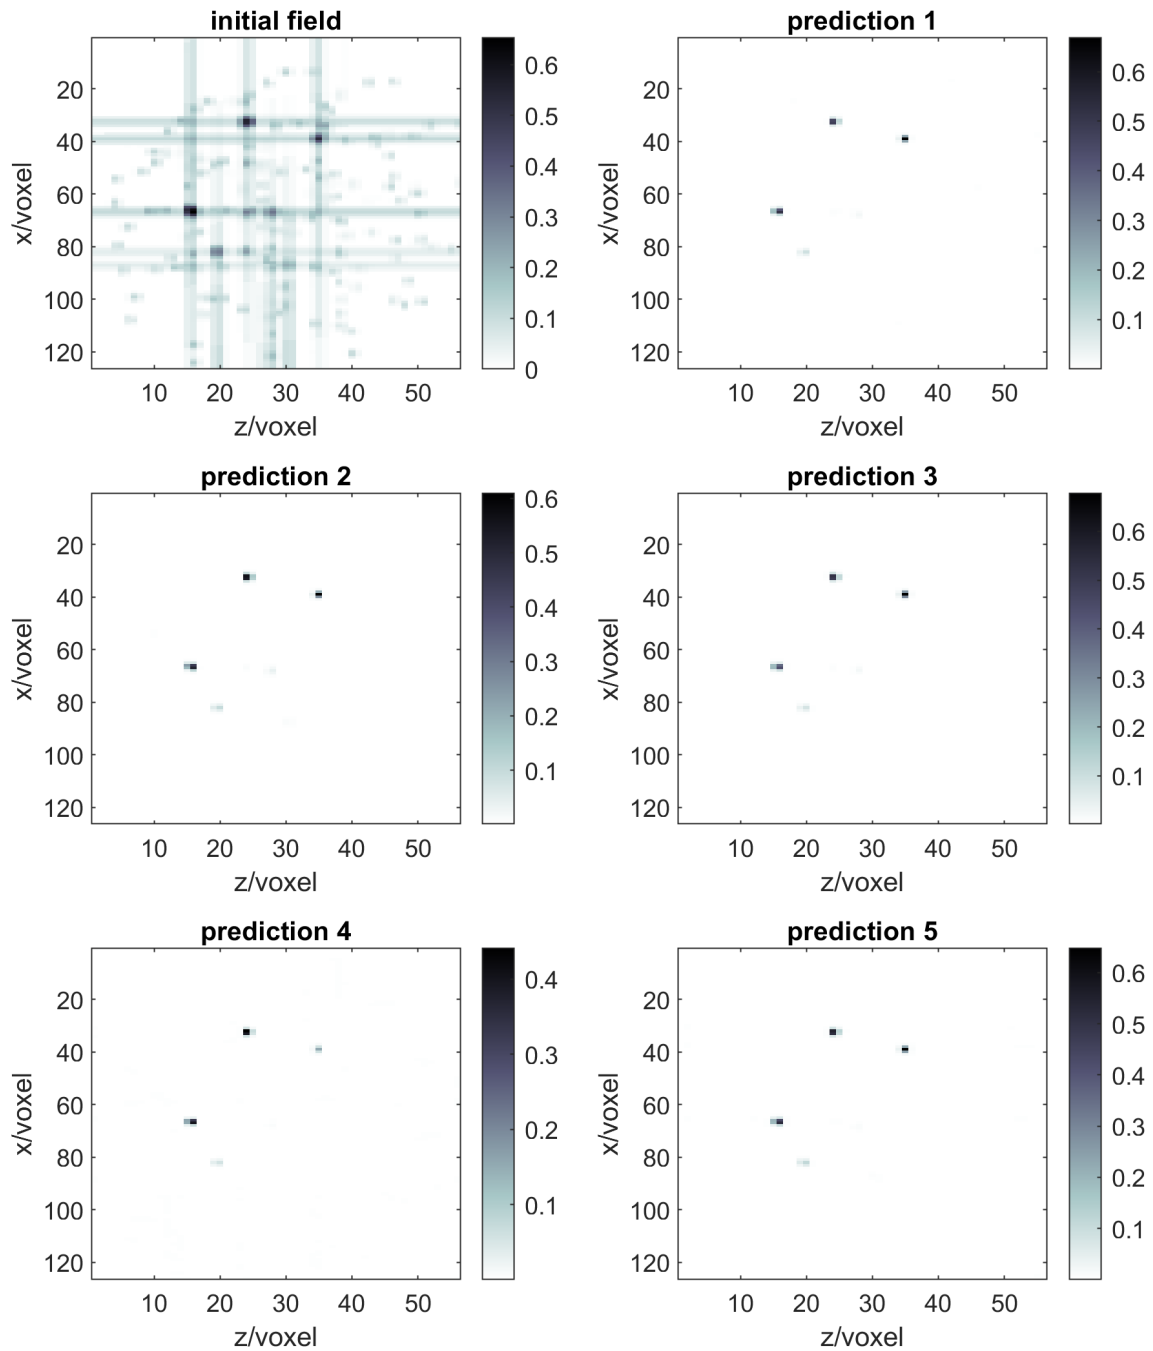


Abbildung 20: Oben links ist das mittels Gl.(45) berechnete initial field und daneben und darunter die berechneten predictions zu sehen. Die Netzwerke wurden mit den gleichen Parametern trainiert wie zuvor, außer, dass die Partikelgröße in den training fields mit einer Varianz von $15 \mu\text{m}$ anstatt $20 \mu\text{m}$ eingestellt wurde. Ausschnitte bei $y = 75$ voxel.

Das Training wurde noch einmal mit einem learn rate drop factor von 0,05 mit den selben Trainingssets wiederholt. dabei lassen sich nur kleine Unterschiede in den prediction fields der verschiedenen trainierten Netze erkennen (siehe Abb. 21). Selbst die maximale Intensität im initial field wird nach Wiederholung des Trainings sehr ähnlich von dem Netz reguliert. Die Intensitätsverteilungen werden in den predictions auf einen Kern mit 2-3 voxel im Durchmesser und einer Mindestintensität von 0,2 komprimiert. Somit lassen sich auch die Teilchenpositionen mittels der Teilchenerkennung besser erfassen. Die durchschnittliche Anzahl der georteten Teilchen pro frame bestätigt, dass die trainierten Netze das initial field sehr ähnlich bearbeiten. Wie in Tab. 14 zu sehen ist, schwankt die Anzahl der erkannten Teilchen lediglich zwischen 58,1 und 63,3. Das ist eine deutliche Verbesserung im Vergleich zu Tab. 13, wenn man den vierten Trainingsdurchlauf mit betrachtet. Die Anteile übereinstimmender Teilchen gleichen fast denen nach den Auswertungen mit den Netzen, die bei einem learn rate drop factor von 0,1 trainiert wurden.

Tabelle 14: Die Auswertung der Anzahl der Teilchen und die übereinstimmenden Anteile erfolgte identisch zu denen in Tab. 13, nur für die mit reduziertem learn rate drop factor von 0,05 trainierten Netze. Somit sind die Werte auch direkt vergleichbar.

Durchlauf	N_{NN}	$n_{\text{NN}}/\%$	$n_{\text{STB}}/\%$
1	60,7	99,5	75,7
2	63,3	99,6	78,5
3	59,2	99,9	74,0
4	62,5	99,7	77,8
5	58,1	99,9	72,2

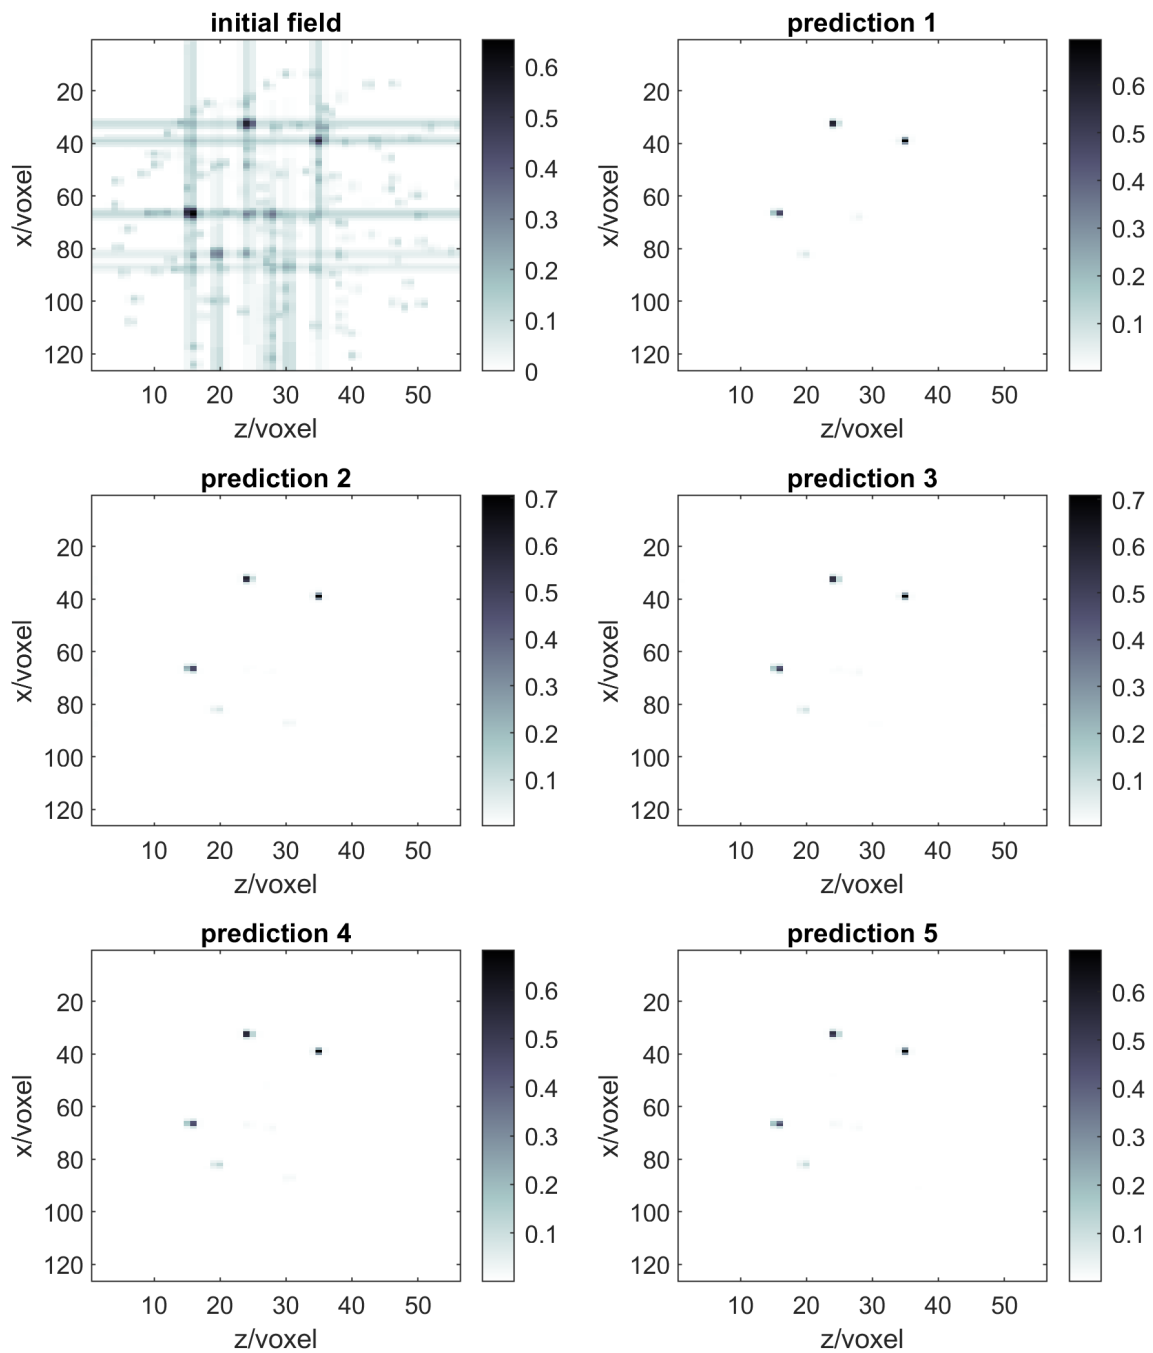


Abbildung 21: Gleiche Stelle aus dem initial field und den predictions wie zuvor. Die Netzwerke wurden bei einem learn rate drop factor von 0,05 trainiert. Alle anderen Parameter und auch die Trainingssets sind mit denen aus Abb. 20 identisch.

6 Zusammenfassung

In dieser Arbeit sollten die Auswirkungen bei Änderungen verschiedener Parameter auf das Training neuronaler Netze zur Verbesserung der Teilchenerkennung in staubigen Plasmen untersucht werden. Im Zentrum stand geeignete Parameter zu finden, um die Auswertung mittels trainierter Netze möglichst reproduzierbar zu machen. Allgemein lassen sich keine statistischen Aussagen treffen, da maximal 5 Wiederholungen des Trainings gemacht wurden, da ein Trainingsdurchlauf je nach Anzahl der voxels zwischen einer und vier Stunden braucht. Man kann aber in den Ergebnissen sehen, dass unter bestimmten Parametern die Ergebnisse deutlich mehr variieren als bei anderen.

So hat sich gezeigt, dass bei Nutzung des geometrischen Mittels zur Berechnung des initial field mit keinen der getesteten Parametern annähernd wiederholbare Ergebnisse erzielt werden konnten. Die Variation des learn rate drop factor hatte kaum Auswirkungen auf die Stabilität der Trainingsdurchläufe. Die Auswirkungen der Vergrößerung des neuronalen Netzes mit 2 zusätzlichen „Blöcken“ vom hidden layer lassen sich durch die 2 durchgeführten Trainingsdurchläufe nicht abschätzen, wobei sie zumindest bei 1200 Trainingssets zu keinem wiederholbaren Training geführt haben. Die Vergrößerung des Gaußfilters zur Bearbeitung der Bilder auf 5×5 Pixel mit einer Varianz von 3 Pixel hat das Training auch nicht signifikant verbessert. Anscheinend tendieren die Kostenfunktionen bei Nutzung des geometrischen Mittels zur Berechnung des initial field viele stark ausgeprägte, lokale Minima zu besitzen, sodass der Lernprozess durch die zufälligen Startparameter der Gewichtungen in den convolution filters zu sehr unterschiedlichen Ergebnissen führt.

Die Nutzung des Durchschnitts zur Berechnung des initial field ist unter den erprobten Parametern bei diesem Messaufbau für das Training und die Auswertung der Messbilder ebenfalls ungeeignet. Die Intensitätsverteilungen sind stark ausgeprägte Strahlen, die sich kreuzen. Diese starken Ausdehnungen der Teilchenintensitätsverteilungen kann das neuronale Netz unter den gewählten Bedingungen nicht lernen zu komprimieren. Eine Erweiterung oder Reduktion der Trainingssets hatte auch keinen positiven Einfluss. Stattdessen haben alle trainierten Netze die Intensität im gesamten initial field stark reduziert, wodurch eine Teilchenerkennung sehr schwer und mit vermehrten Falscherkennungen verbunden ist.

Die stabilsten Ergebnisse bei wiederholtem Training wurden mit der letzten Berechnungsmethode der initial fields erreicht. Durch die Bildung des Durchschnitts der beiden vorherigen initial fields konnten bereits bei einem learn rate drop factor von 0,1 ziemlich stabile Trainingsdurchläufe durchgeführt werden. Eine Verkleinerung des learn rate drop factor auf 0,05 hat die Trainingsdurchläufe noch mehr verbessert. Diese Ergebnisse bestätigten sich auch bei der Auswertung der Messbilder der zweiten Messung. Dabei gab es keinen großen Unterschied in der Wiederholbarkeit der Trainingsdurchläufe bei Variation der Partikelgröße im training field. Alle trainierten Netz für beide Messungen konnten die Intensität der Streifen in den initial fields so stark senken, dass sie nicht mehr zu erkennen sind und gleichzeitig die Teil-

chen auf eine einheitliche Größe komprimieren, sodass eine Auswertung mit dem Teilchenerkennungsprogramm vereinfacht wird.

Das neuronale Netz ist also sehr gut zur Verbesserung der Teilchendetektion geeignet, wobei nicht nur die Erstellung der Trainingsbilder, sondern auch die Berechnung der initial fields an den jeweiligen Messaufbau angepasst werden müssen. Dabei müssen die initial fields eine gewisse Ungenauigkeit aufweisen, damit das neuronale Netz besser lernen kann die Intensitätsverteilungen einheitlich zu komprimieren. Da die Cluster bei den beiden Messungen sehr dicht bei einander liegen, könnte man auch versuchen ein Netz zu trainieren, welches beide Messungen auswerten kann. Dabei ist die Qualität der Auswertung jedoch von der Speicherkapazität der GPU abhängig, da dadurch die Anzahl der voxels beschränkt ist.

Literatur

- [1] I. de Pater, D. Hamilton, M. Showalter, H. Throop, and J. Burns. The rings of jupiter. *Cambridge University Press*, 2017.
- [2] P. Bliokh, V. Sinitsin, and V. Yaroshenko. *Dusty and Self-Gravitational Plasmas in Space*. Springer, 1995.
- [3] G. E. Elsinga, F. Scarano, B. Wieneke, and B. W. van Oudheusden. Tomographic particle image velocimetry. *Exp Fluids*, 41(933-947), 2006.
- [4] M. Mulsow, M. Himpel, and A. Melzer. Analysis of 3d vortex motion in a dusty plasma. *Physics of Plasmas*, 24(12), 2017.
- [5] D. Schanz, S. Gesemann, and A. Schröder. Shake-the-box: Lagrangian particle tracking at high particle image densities. *Exp Fluids*, 57, 2016.
- [6] M. Himpel and A. Melzer. Three-dimensional reconstruction of individual particles in dense dust clouds: Benchmarking camera orientations and reconstruction algorithms. *Journal of Imaging*, 5(2), 2019.
- [7] H. Huang, M. Schwabe, and C.-R. Du. Identification of the interface in a binary complex plasma using machine learning. *Journal of Imaging*, 5(3), 2019.
- [8] C. Dietz, J. Budak, T. Kamprich, M. Kretschmer, and M. H. Thoma. Phase transition in electrorheological plasmas. *Contributions to Plasma Physics*, 61(10), 2021.
- [9] C. Wang, X. Sun, and H. Li. Research on pedestrian tracking algorithm based on deep learning framework. *Journal of Physics: Conference Series*, 1176, 2019.
- [10] M. Himpel and A. Melzer. Fast 3d particle reconstruction using a convolutional neural network: application to dusty plasmas. *Machine Learning: Science and Technology*, 2(4), 2021.
- [11] A. Piel. *Plasma Physics. An Introduction to Laboratory, Space and Fusion Plasmas*. Springer, 2010.
- [12] H. M. Mott-Smith and I. Langmuir. The theory of collectors in gaseous discharges. *Physical Review*, 28(727), 1926.
- [13] A. Melzer. *Physics of Dusty Plasmas, An Introduction*. Springer, 2019.
- [14] P. S. Epstein. On the resistance experienced by spheres in their motion through gases. *Physical Review*, 23(710), 1924.
- [15] M. S. Barnes, J. H. Keller, J. C. Forster, J. A. O'Neill, and D. K. Coultas. Transport of dust particles in glow-discharge plasmas. *Phys. Rev. Lett.*, vol. 68:pp. 313–316, 1992.

- [16] M. Mulsow and A. Melzer. Experimental determination of phase transitions by means of configurational entropies in finite yukawa balls. *Phys. Rev. E*, 96, 2017.
- [17] A. Schella, M. Mulsow, A. Melzer, J. Schablinski, and D. Block. From transport to disorder: Thermodynamic properties of finite dust clouds. *Phys. Rev. E*, 87, 2013.
- [18] Matthias Mulsow. *Size-sensitive phenomena in finite Yukawa-balls*. PhD thesis, 2018.
- [19] M. himpel, 2020, camera calibration and 3d particle tracking toolbox for matlab. <https://physik.uni-greifswald.de/arbeitsgruppen/experimentelle-physik/kolloidale-plasmen-prof-andre-melzer/forschung/stereo-toolbox/>.
- [20] M. himpel, 2021, aipr toolbox for matlab. <https://physik.uni-greifswald.de/ag-melzer/aipr-toolbox/>.
- [21] Q. Gao, Q. Li, S. Pan, H. Wang, W. Runjie, and J. Wang. Particle reconstruction of volumetric particle image velocimetry with strategy of machine learning. arXiv:1909.07815v1, 2019.