

Ordinale Klassifikation mit neuronalen Netzen in DSEA

Nicolai Weitkemper

14.10.2022

Inhalt

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN
Konfiguration
Hyperparametersuche
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

Nominale und ordinale Daten

- Nominale Daten: *Kategorien*
 - z. B. „Elektron“, „Myon“, „Tauon“
 - *Keine* natürliche Ordnung
- Ordinale Daten: *Rangfolge*
 - z. B. „schlecht“, „mittel“, „gut“
 - Natürliche Ordnung
- → Neutrinoenergien sind *ordinale* Daten
(sogar *metrisch*)

Vorgängerarbeiten

- DSEA⁺ mit ordinaler Klassifikation: 
 - Vorteil: Konfidenzverteilungen physikalisch sinnvoll(er)
 - → siehe Jäkel¹
- DSEA⁺ mit neuronalen Netzwerken: 
 - Vorteil: Flexibel, evtl. bessere Performance
 - → siehe Haefs²
- DSEA⁺ mit neuronalen Netzwerken *und* ordinaler Klassifikation: 
 - → Thema dieser Arbeit

¹Jäkel, „Ordinal Classification in DSEA“.

²Haefs, „Lösungen inverser Probleme“.

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

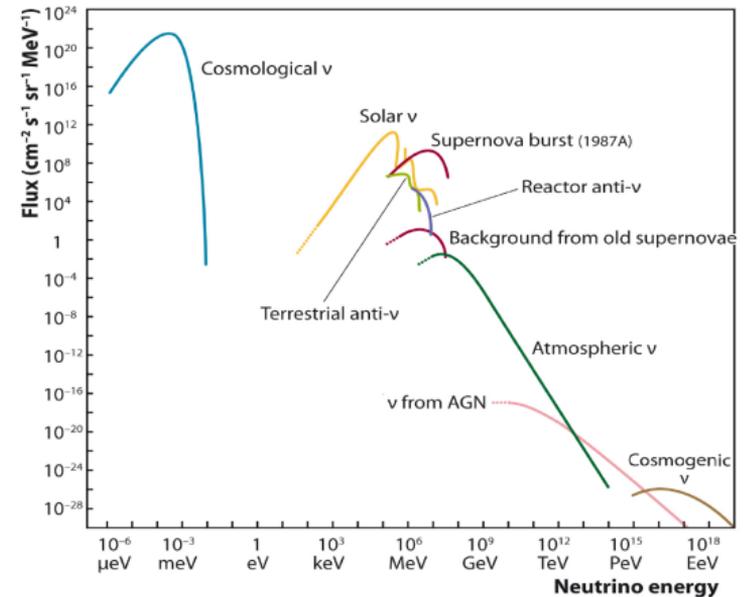
Ordinale Klassifikation
CORN

Entfaltung mit CORN
Konfiguration
Hyperparametersuche
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

Neutrinos

- Ungeladene, schwach wechselwirkende Elementarteilchen
- Botenteilchen
 - Unbeeinflusst von Magnetfeldern
 - Durchdringen Materie (fast) unbehindert
- Quellen:
 - Urknall (CNB)
 - Supernovae
 - Aktive Galaxienkerne
 - ...

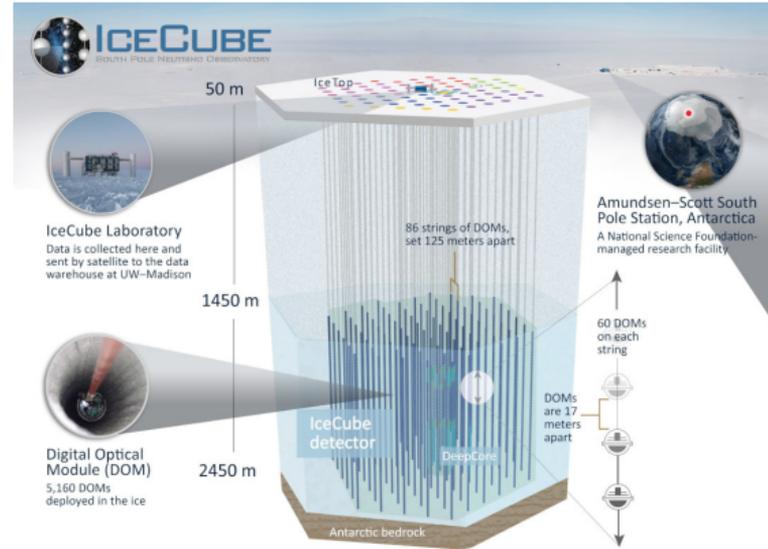


Bildquelle: (Spiering, „Towards high-energy neutrino astronomy“)

IceCube

- Neutrino-Detektor am Südpol
- Indirekte Detektion mittels Cherenkov-Licht von Reaktionsprodukten
- Ziele:
 - Richtung / Quelle
 - Flavor
 - Energie
 - ...
- Energiebereich: GeV bis PeV^a

^aAartsen u. a., „The IceCube Neutrino Observatory: instrumentation and online systems“.



Bildquelle: (IceCube Collaboration, [IceCube](#))

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN
Konfiguration
Hyperparametersuche
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

Entfaltungsproblem I

- Unsere Messungen sind *indirekt*
→ Für eine physikalische Wahrheit $f(x)$ können wir nur Messungen $g(y)$ durchführen
- Fredholmsche Integralgleichung¹:

$$\int_a^b A(x, y) f(x) dx = g(y)$$

- Diskretisiert:

$$\mathbf{A}\vec{f} = \vec{g}$$

- Naive Lösung: Invertieren der Matrix \mathbf{A} :

$$\vec{f} = \mathbf{A}^{-1}\vec{g}$$

Entfaltungsproblem II

- Problem: **A** ist meist schlecht konditioniert
 - Numerisch instabil
 - Oszillationen
- Verschiedene verbesserte Ansätze:
 - Time-dependent Regularized Unfolding for Economics and Engineerings (TRUEE) / Regularized Unfolding (RUN)¹
 - Iterative Bayesian Unfolding (IBU)²
 - DSEA⁺

¹Fredholm, „Sur une classe d'équations fonctionnelles“.

¹Milke u. a., „Solving inverse problems with the unfolding program TRUEE: Examples in astroparticle physics“.

²D'Agostini, „A multidimensional unfolding method based on Bayes' theorem“; D'Agostini, „Improved iterative Bayesian unfolding“.

DSEA⁺ – Idee

- DSEA⁺ = **D**ortmund **S**pectrum **E**stimation **A**lgorithm¹
- Fasse das Entfaltungsproblem als *Klassifikationsproblem* auf
 - Diskretisiere die Zielvariable in Bins
 - Trainiere einen Klassifizierer darauf, zu einer gegebenen Messung den Energie-Bin zu finden
 - Prinzipiell eignet sich jeder Klassifizierer (z. B. Random Forests², NN'e, ...)
- Summiere die Konfidenzen auf, um das gesamte Energiespektrum zu erhalten
→ Besser als nur die jeweils wahrscheinlichsten Bin-Zuordnungen aufzusummieren
- Aktualisiere die Gewichte jedes Bins iterativ abhängig vom rekonstruierten Spektrum
- Ziel: Konvergenz & Unabhängigkeit vom Spektrum der Monte-Carlo-Trainingsdaten

¹Bunse u. a., „[Unification of Deconvolution Algorithms for Cherenkov Astronomy](#)“.

²Hymon und Ruhe, „[Seasonal Variations of the Unfolded Atmospheric Neutrino Spectrum with IceCube](#)“.

DSEA⁺ – Algorithmus

- Initialisierung

- Nehme einen gleichverteilten Prior an: $\hat{\mathbf{f}}_i^{(0)} = \frac{1}{I} \quad \forall i$
- Gewichtung s. u.

- Iteration

- Training (gewichtet gemäß $\mathbf{w}_i^{(k)}$)
- Rekonstruiere das Test-Spektrum als Summe von Konfidenzen
- Optionale Zwischenschritte (gekürzt):
 - (Adaptive) Schrittweite α
 - Regularisierung

- Umgewichtung: $\mathbf{w}_i^{(k+1)} = \frac{\hat{\mathbf{f}}_i^{(k)}}{\mathbf{f}_i^{\text{train}}}$

- Abbruch / Konvergenz:

- Nach K Iterationen
- Bei Unterschreiten einer χ^2 -Distanz zur vorherigen Schätzung

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN
Konfiguration
Hyperparametersuche
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

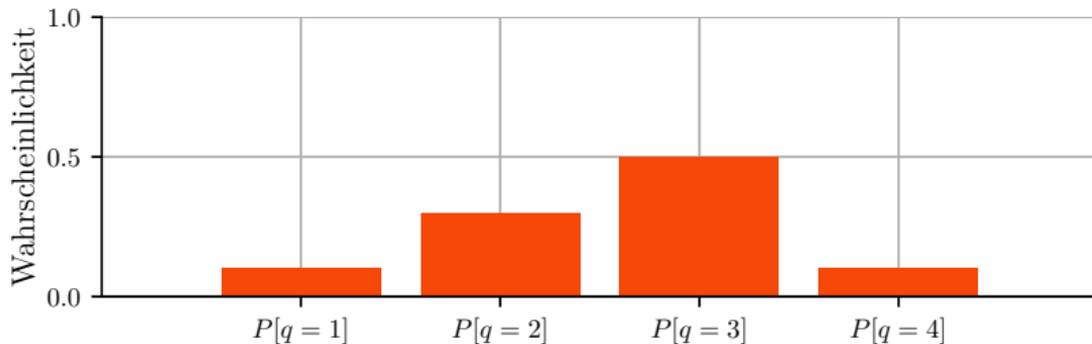
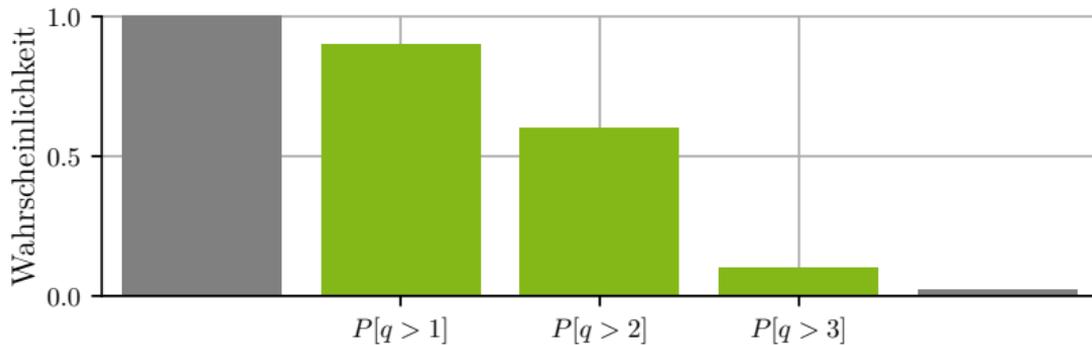
CORN – Funktionsweise

- CORN = **C**onditional **O**rdinal **R**egression for **N**eural Networks
- Unterteile die Aufgabe, den Rang-Index $q \in \{1, 2, 3, 4\}$ vorherzusagen, in binäre Teilaufgaben:
 $P[q > 1]$, $P[q > 2 | q > 1]$, $P[q > 3 | q > 2]$
- Berechne die unbedingten Wahrscheinlichkeiten:
 $\hat{P}[q > 2] = \hat{P}[q > 2 | q > 1] \cdot \hat{P}[q > 1]$,
 $\hat{P}[q > 3] = \hat{P}[q > 3 | q > 2] \cdot (\hat{P}[q > 2 | q > 1] \cdot \hat{P}[q > 1])$ usw.
 - Erzwingt $\hat{P}[q > 1] \geq \hat{P}[q > 2] \geq \hat{P}[q > 3] \geq \dots$
- Vorhersage: $\hat{q} = 1 + \sum_k \mathbb{1} \{ \hat{P}[q > k] > 0.5 \}$

CORN – Ermittlung von Konfidenzen

- Bisher liefert CORN $P[q > 1]$, $P[q > 2]$ usw. und daraus eine Rang-Vorhersage \hat{q} .
- Aber wir benötigen $P[q = 1]$, $P[q = 2]$ usw.
- Unter der Annahme, dass es keine Energien außerhalb der gegebenen Bins gibt, gilt z. B. für $q \in \{1, 2, 3, 4\}$:
 - $P[q = 1] = 1 - P[q > 1]$
 - $P[q = 2] = P[q > 1] - P[q > 2]$
 - $P[q = 3] = P[q > 2] - P[q > 3]$
 - $P[q = 4] = P[q > 3]$

CORN – Beispiel



Ordinale Klassifikation

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN
Konfiguration
Hyperparametersuche
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

Datensatz

- Datensatz 11374¹
 - Monte-Carlo-Simulation
 - Nur „upgoing“ ν_μ
 - E^{-2} -Spektrum
 - 13 Mio. Ereignisse
 - 500 000 davon verwendet (vgl. Haefs²)
 - 94 Features verfügbar
- Zielvariable: **MCPrimary.energy**
- 12 Features³
 - Selektion mit *MRMR* (Maximum Relevance — Minimum Redundancy)
 - Yeo-Johnson-Transformation (reduziert Schiefe) und Skalierung auf Standardabweichung

¹IceCube Collaboration, *Dataset 11374*.

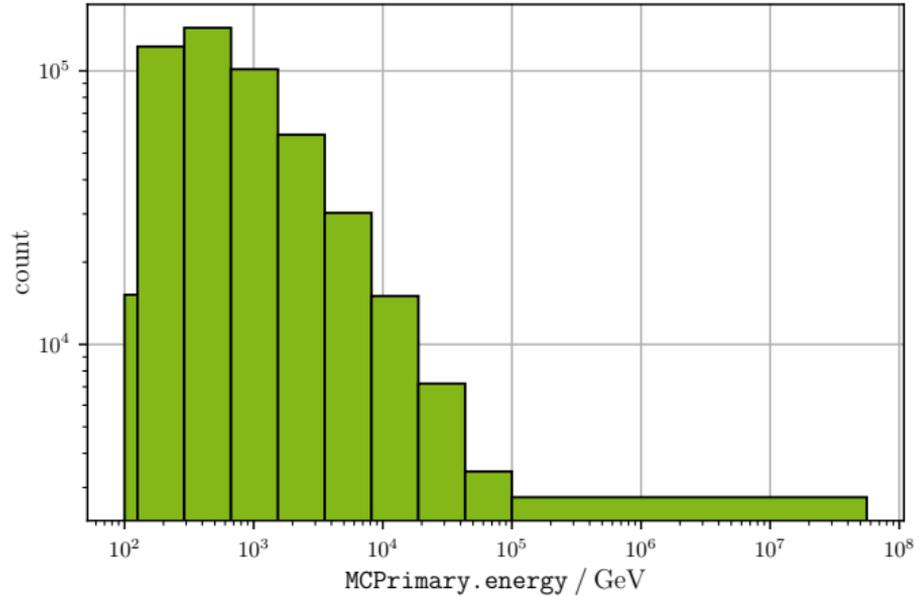
²Haefs, „*Lösungen inverser Probleme*“.

³übernommen aus Jäkel (Jäkel, „*Ordinal Classification in DSEA*“)

Bins

- 10 Bins
- Under-/Overflow-Bins
 - Untere Grenze: $10^{2.1}\text{GeV}$
 - Obere Grenze: 10^5GeV
(vgl. Haefs^a)

^aHaefs, „Lösungen inverser Probleme“.



Neuronales Netzwerk

- Form der Hidden Layers: **120, 240, 120, 12** fully connected (vgl. Haefs¹)
- Aktivierungsfunktion: **Leaky ReLU**
- Output-Layer: von CORN bereitgestellt
 - Ergänzt um die Berechnung von Konfidenzen (statt des wahrscheinlichsten Ranges)
- Verlustfunktion: von CORN bereitgestellt
 - Ergänzt um eine Gewichtung der Beispiele
- Optimierer: Adaptive Moment Estimation (Adam)

¹Haefs, „Lösungen inverser Probleme“.

Weitere Hyperparameter

- Maximal $K = 20$ DSEA⁺-Iterationen
→ nie erreicht
- Verwende adaptive Schrittweite ¹

¹aus dem Python-Paket `CherenkovDeconvolution` (Bunse, [CherenkovDeconvolution.py](#))

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN

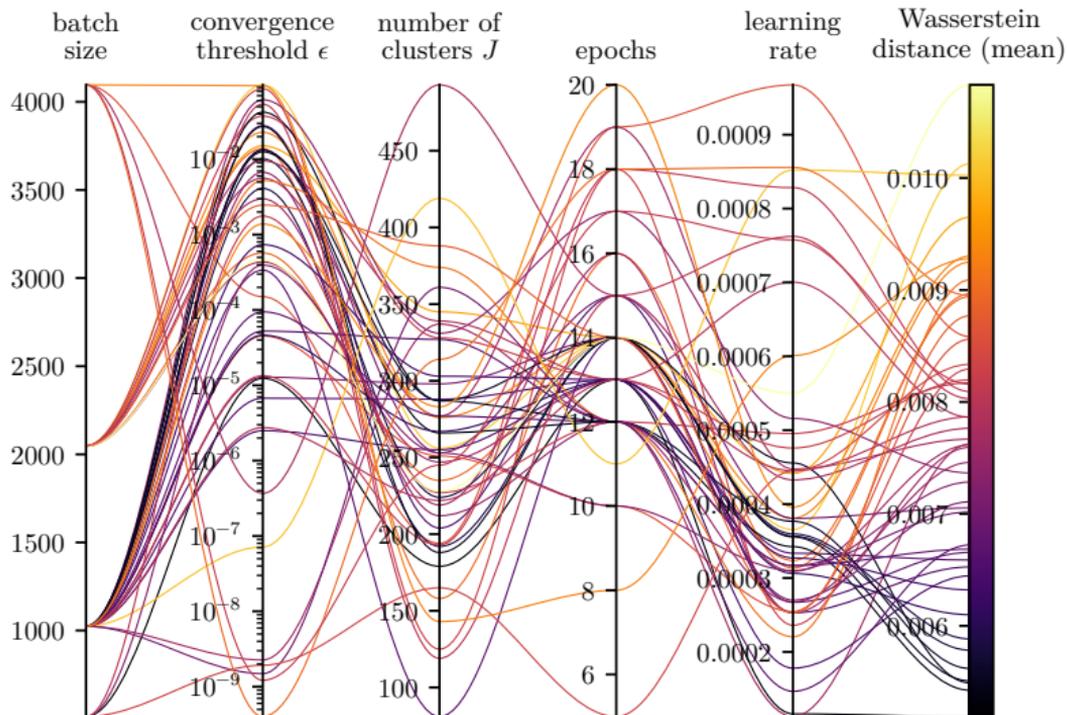
Konfiguration

Hyperparametersuche

Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

Bayesische Optimierung



Entfaltung mit CORN

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN

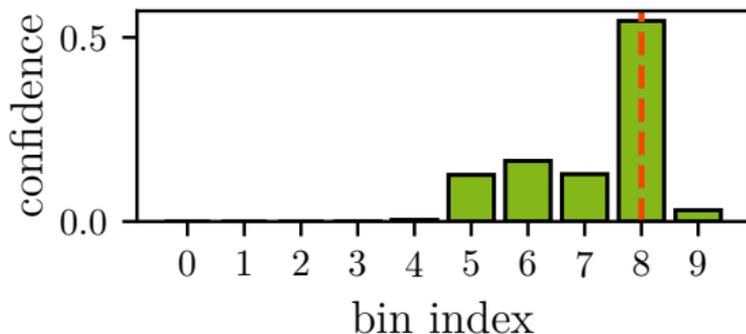
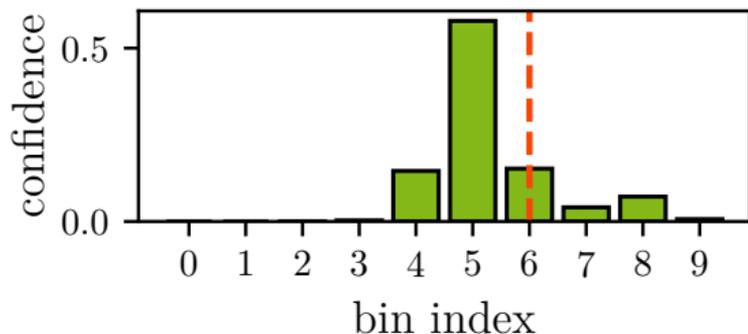
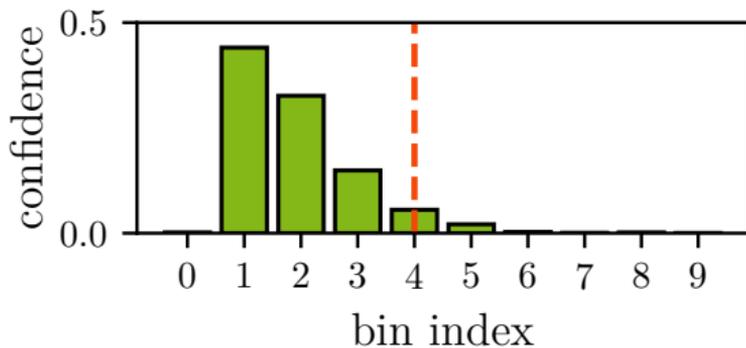
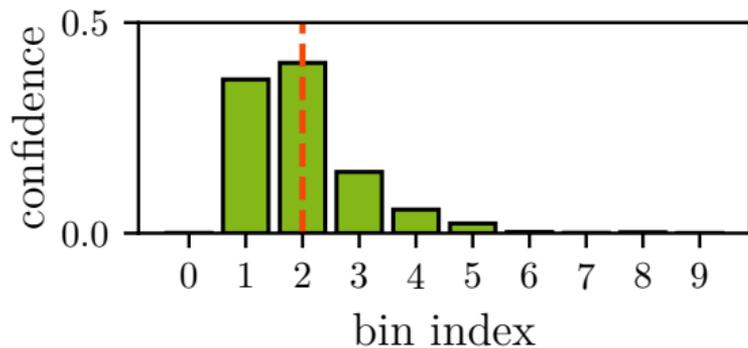
Konfiguration

Hyperparametersuche

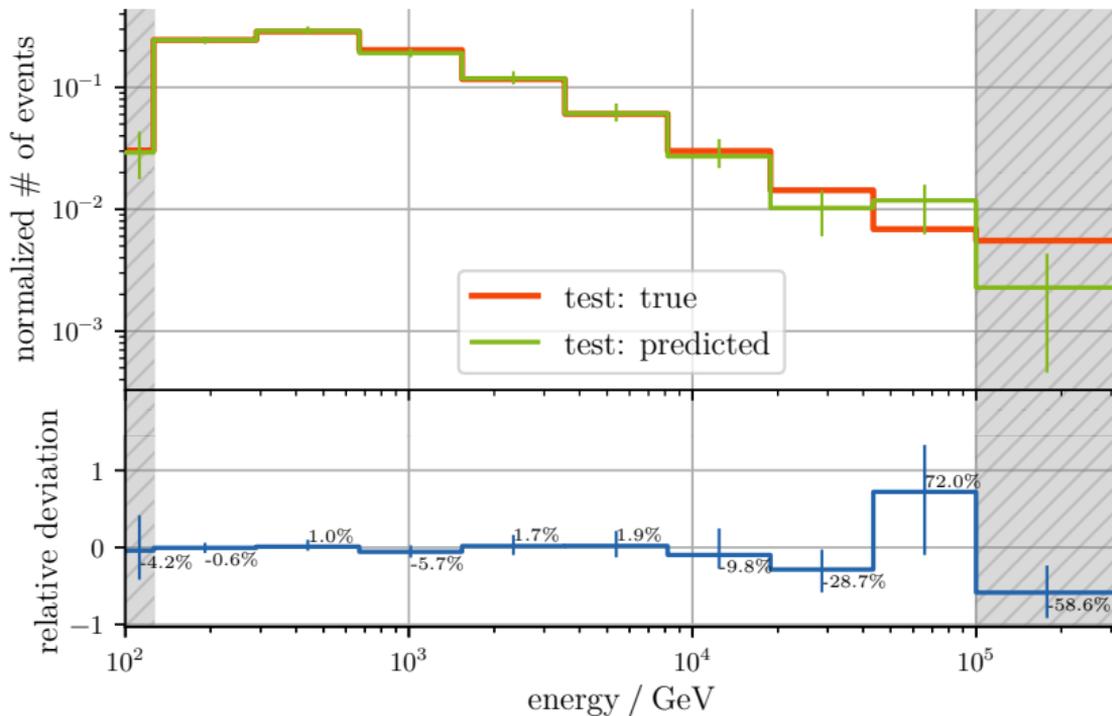
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

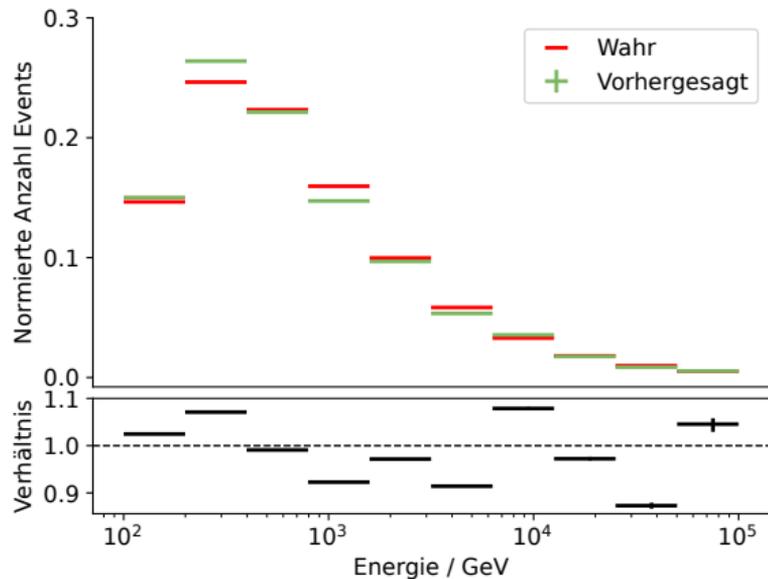
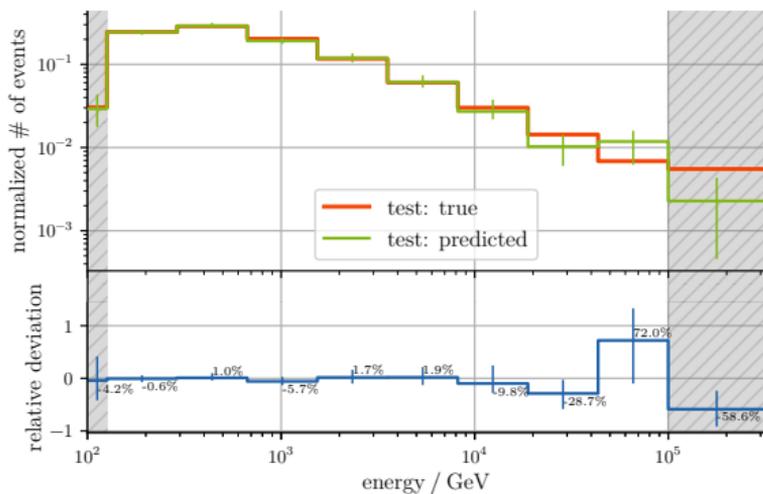
Konfidenzen für einzelne Ereignisse



Spektrum



Spektrum – Vergleich mit Haefs¹

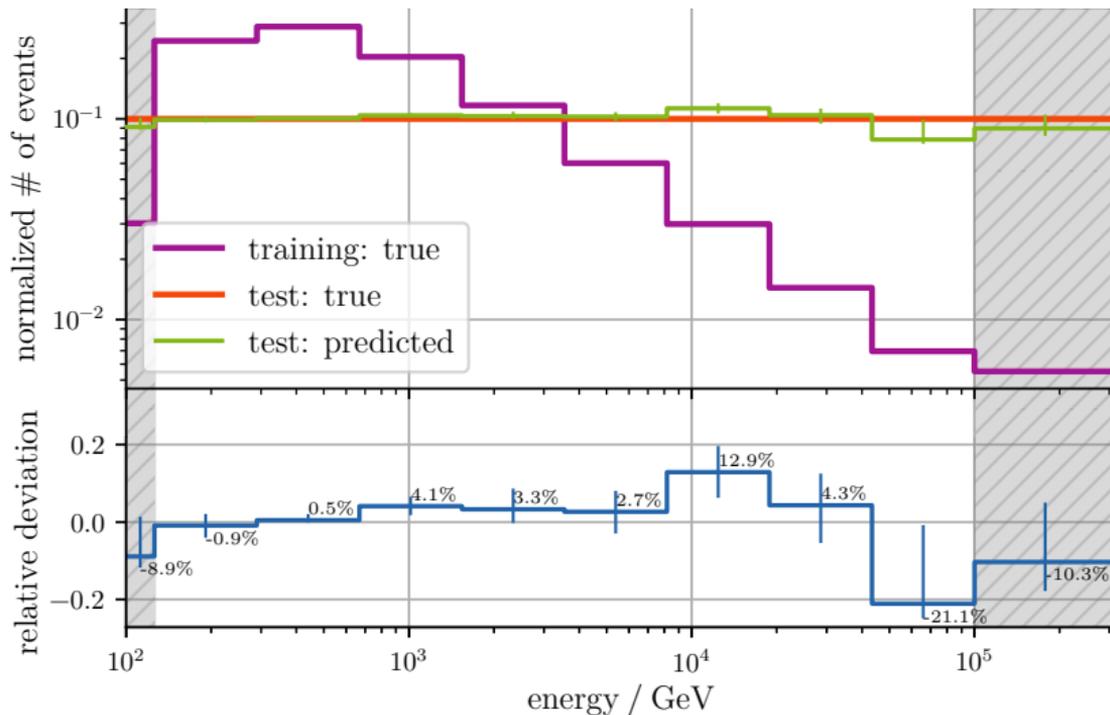


¹Haefs, „Lösungen inverser Probleme“.

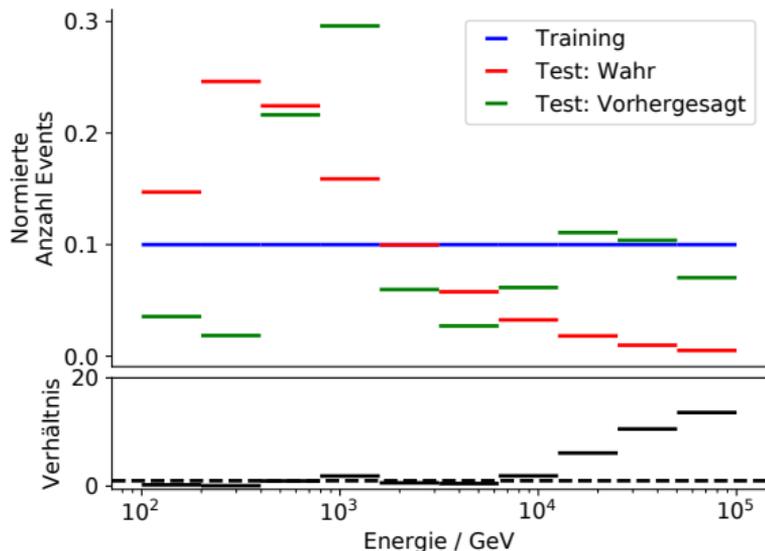
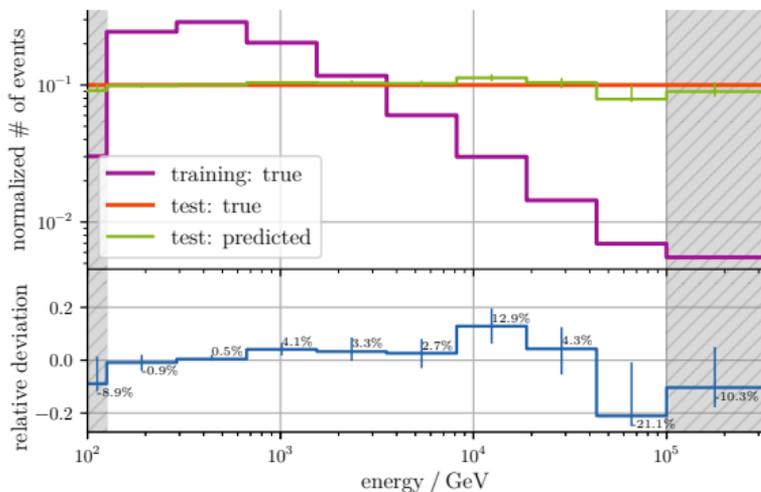
Bias

- Ein Klassifizierer könnte direkt das Trainings-Spektrum als Konfidenzen ausgeben
 - Perfekte Ergebnisse, aber nichts gelernt
 - Bias
- DSEA⁺ soll den Bias durch (Um-)Gewichtung minimieren
- Ansatz zur Überprüfung:
 - Training auf E^{-2} -Spektrum (wie bisher)
 - Test auf einem gleichverteilten Spektrum

Bias



Bias – Vergleich mit Haefs¹



¹Haefs, „Lösungen inverser Probleme“.

Übersicht

Neutrinoastronomie

Lösung des Entfaltungsproblems mit DSEA⁺
DSEA⁺

Ordinale Klassifikation
CORN

Entfaltung mit CORN
Konfiguration
Hyperparametersuche
Unsicherheit & Ergebnisse

Zusammenfassung & Ausblick

Zusammenfassung

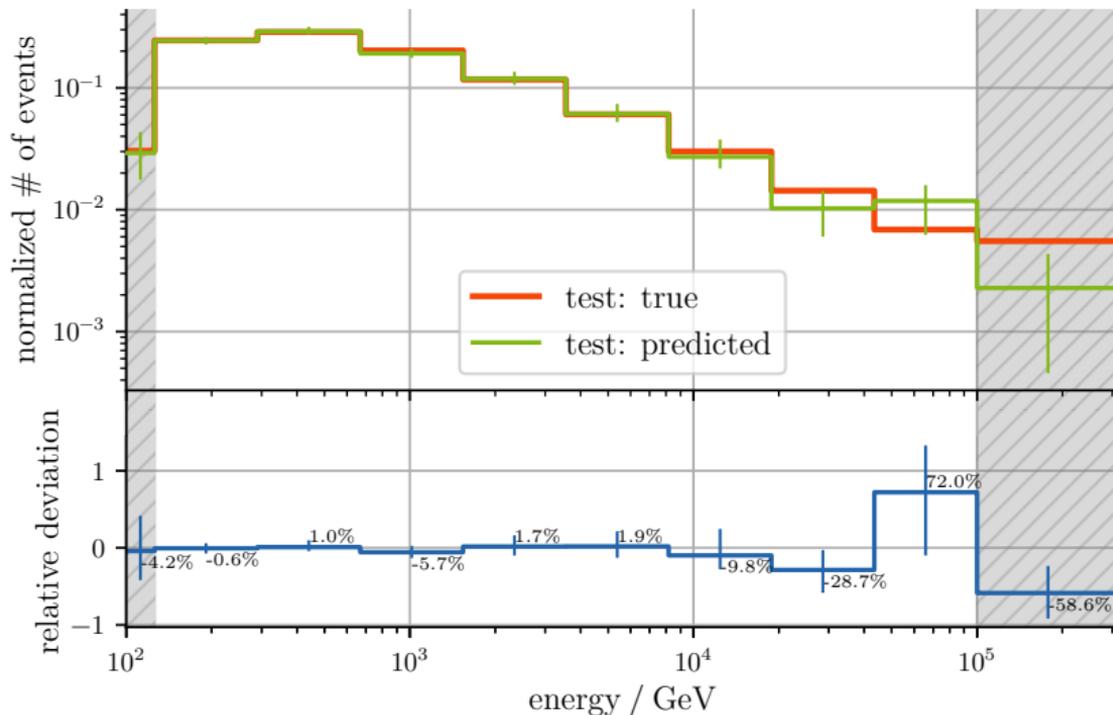
- Physikalisch sinnvolle Konfidenzverteilungen (mit Einschränkungen)
- Oszillationen in den höheren Energiebereichen
- CORN verbessert Bias drastisch (ggü. normalem NN)

Ausblick

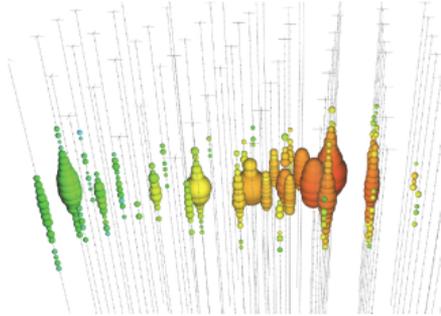
- (Explizite) Regularisierung
- Mehr (/gleichverteilte) Trainingsdaten
- Prüfung weiterer Hyperparameter, z. B. der Form des neuronalen Netzes
→ CORN schränkt nur die Form des Output-Layers ein
- Adaptiere DSEA⁺ für metrische Daten / Regression
- Verwende Graph Neural Networks (GNNs) auf „rohen“ Daten (Zeit, Ort, Ladung)
→ Schlägt Boosted Decision Trees (BDTs) in Auflösung *und* Geschwindigkeit¹

¹Minh, „[Reconstruction of Neutrino Events in IceCube using Graph Neural Networks](#)“.

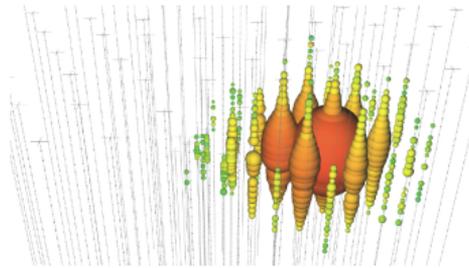
Ende des Vortrags



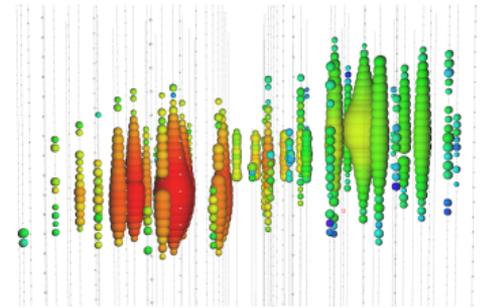
IceCube – Detektorsignaturen



Track / ν_μ



Cascade / ν_e



Double bang / ν_τ

DSEA⁺ – Vorteile

- Beliebige Anzahl an Input-Variablen möglich
- Information über einzelne Ereignisse (/ Beiträge zum Spektrum) bleibt vollständig erhalten
→ Rekonstruktion von z. B. zeitabhängigen Spektren¹

¹Bunse, „DSEA Rock-Solid“.

¹Quelle: Folien zu SMD-B

DSEA⁺ – Voraussetzungen

- Diskretisierte Energien (Bins)
- Der Klassifizierer muss Konfidenzen für jede Klasse zurückgeben
- Die Referenz-Implementierung¹ geht von einem **sklearn**-Klassifizierer aus

¹Bunse, [CherenkovDeconvolution.py](#).

CORN – Ermittlung von Konfidenzen – „Beweis“ I

- Es gebe 3 Energie-Klassen/Bins, genannt **1, 2, 3**
- CORN's Output-Layer gibt uns (nach Anwendung von **sigmoid** und einem kumulativen Produkt) zwei Wahrscheinlichkeiten:
 - $P[y > 1]$
 - $P[y > 2]$
- Gesucht: $P[y = 1], P[y = 2], P[y = 3]$

CORN – Ermittlung von Konfidenzen – „Beweis“ II

- Sei $y \in \{1, 2, 3\}$
- Dann gilt $P[y = 1] \iff \neg P[y > 1] = 1 - P[y > 1]$



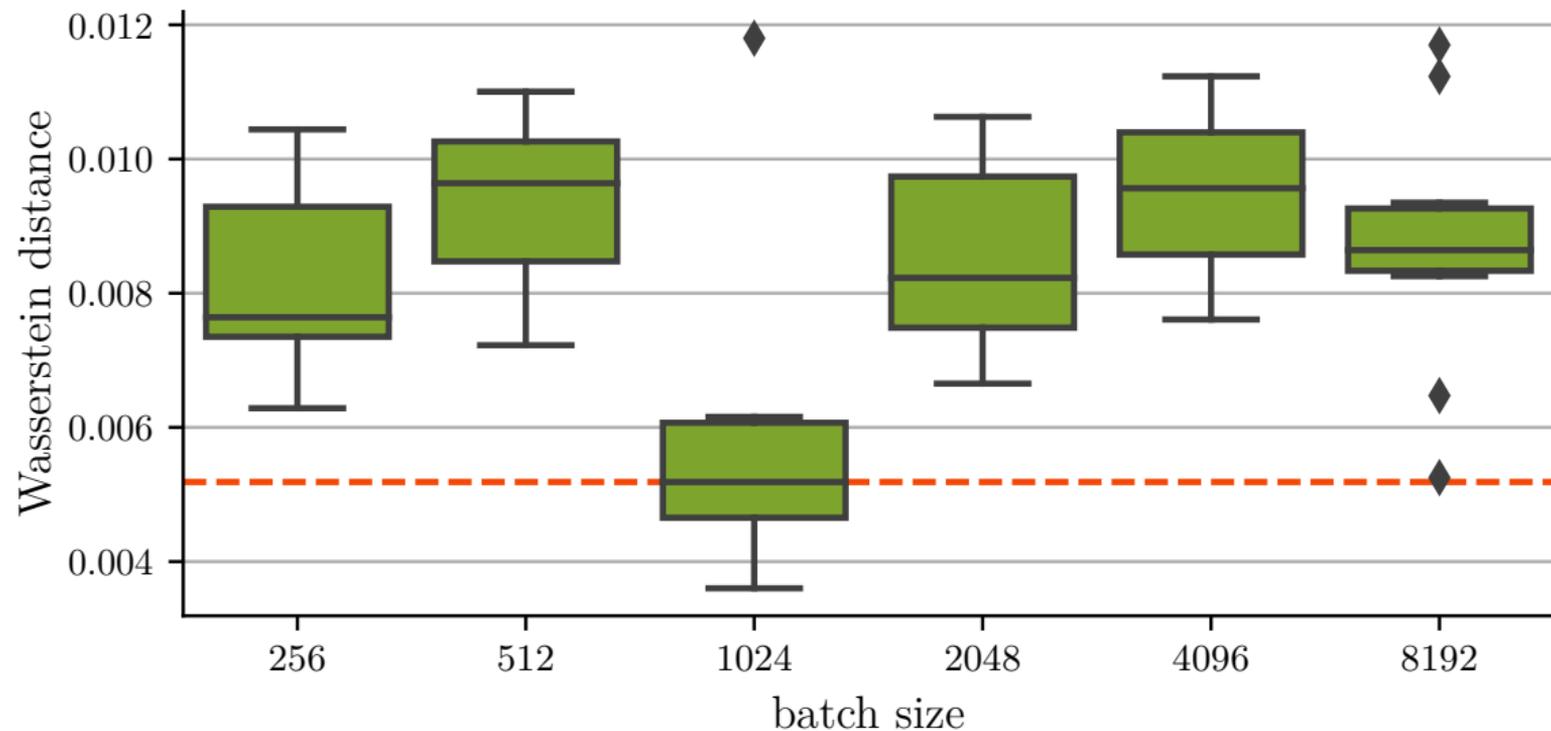
$$\begin{aligned} P[y = 2] &\iff \neg P[y \neq 2] \iff \neg(P[y < 2] \vee P[y > 2]) \iff \neg(P[y = 1] \vee P[y = 3]) \\ &= 1 - ((1 - P[y > 1]) + P[y = 3]) \\ &= P[y > 1] - P[y > 2] \end{aligned}$$

- $P[y = 3] \iff P[y > 2]$
- Fertig!  

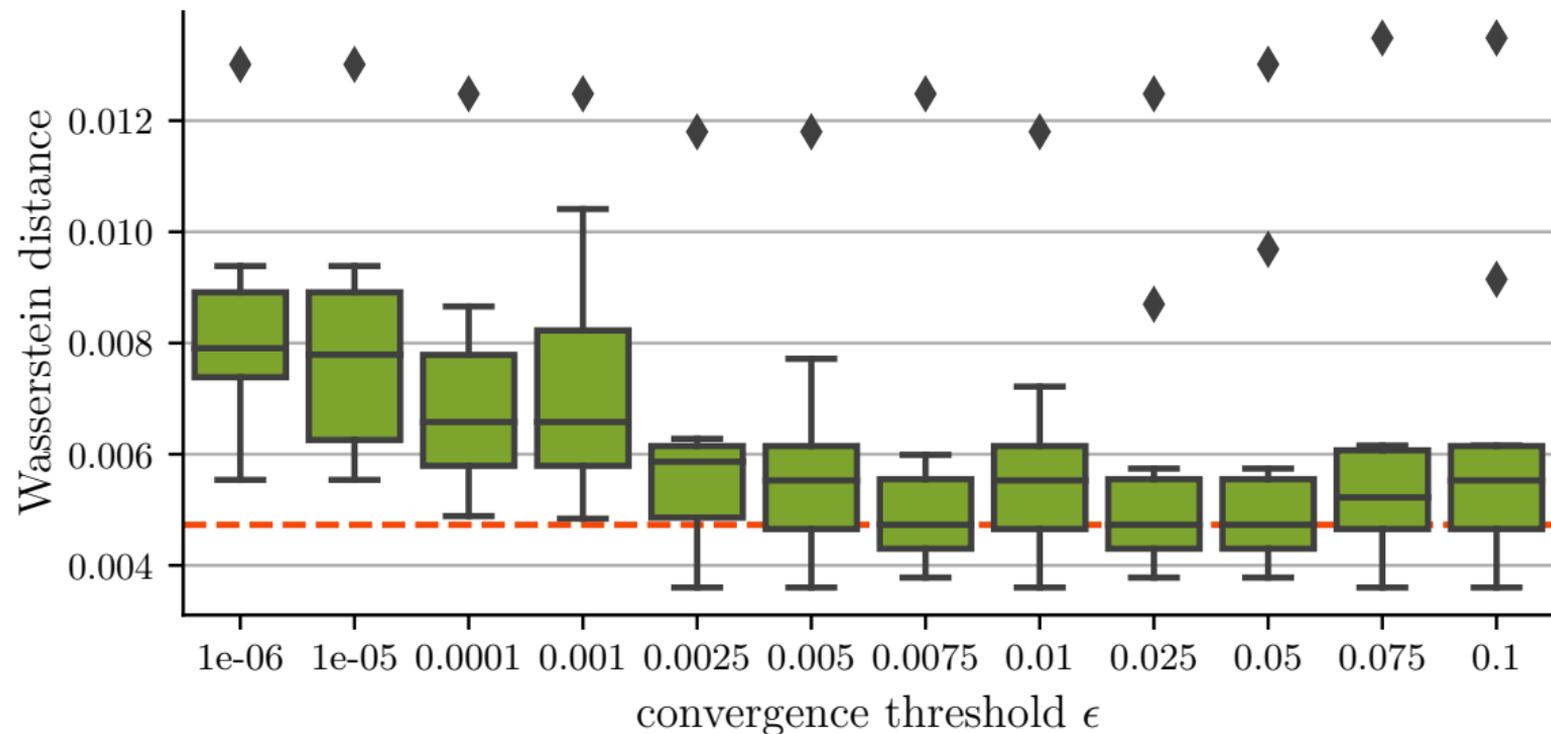
Liste von Features

- MCPrimary.energy
- SplineMPEDirectHitsICE.n_dir_doms
- VariousVariables.Cone_Angle
- SplineMPECramerRaoParams.variance_theta
- Borderness.Q_ratio_in_border
- SplineMPETruncatedEnergy_SPICEMie_BINS_MuEres.value
- SplineMPETruncatedEnergy_SPICEMie_DOMS_Neutrino.energy
- SplineMPEDirectHitsICB.n_late_doms
- Dustyness.n_doms_in_dust
- LineFitGeoSplit1Params.n_hits
- SplineMPEDirectHitsICC.dir_track_hit_distribution_smoothness
- SPEFit2GeoSplit1BayesianFitParams.logl
- SplineMPECharacteristicsIC.avg_dom_dist_q_tot_dom

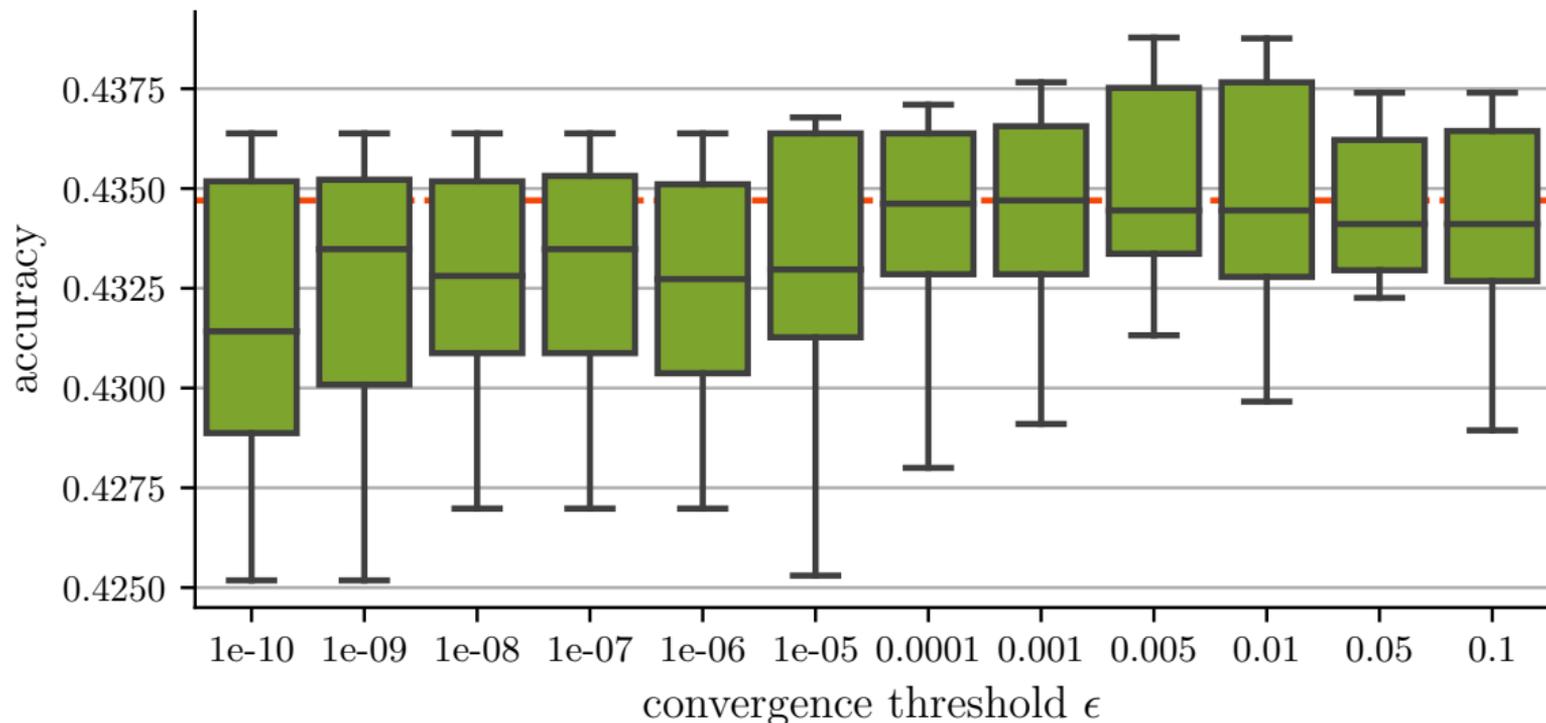
Hyperparametersuche – batch size



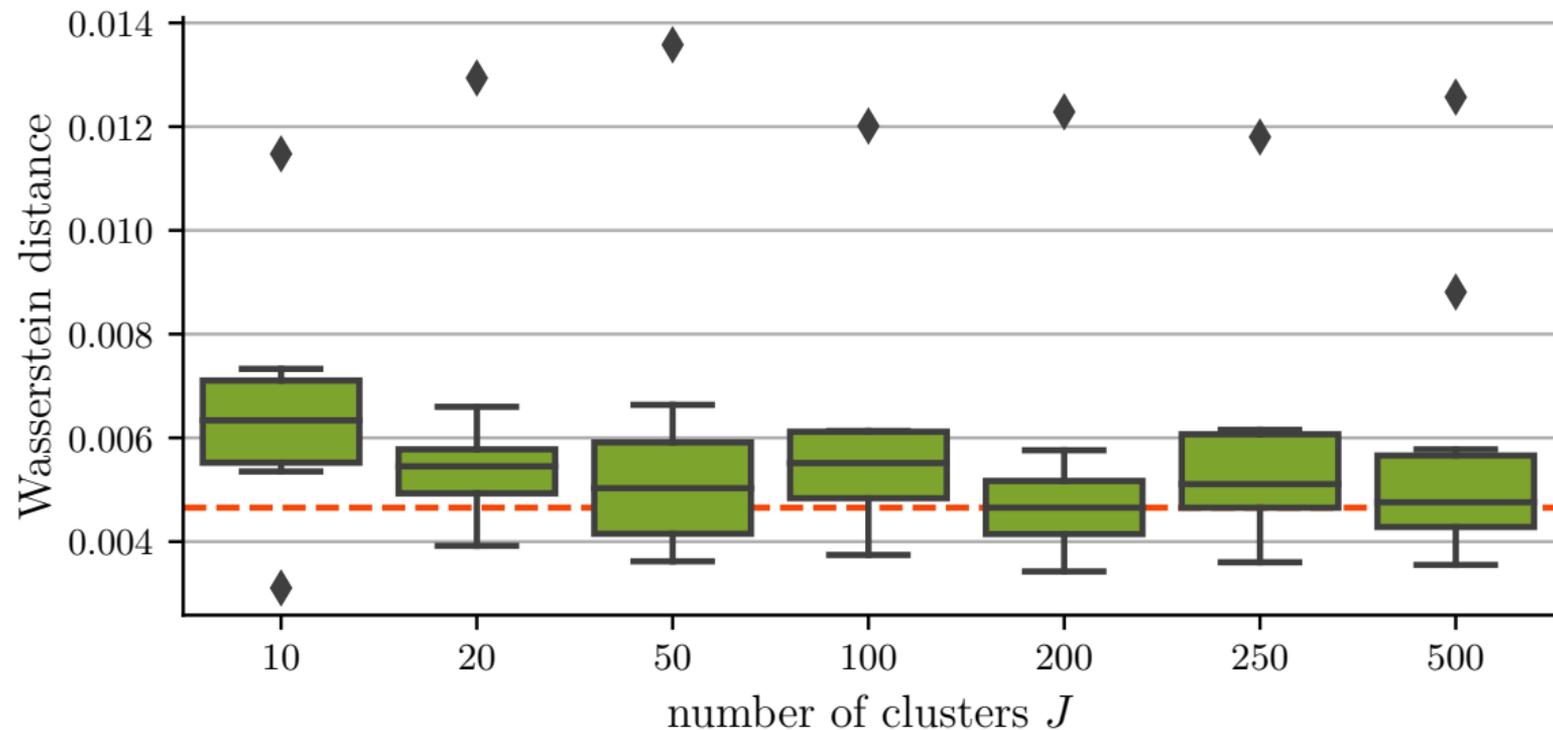
Hyperparametersuche – Konvergenzschwelle ϵ



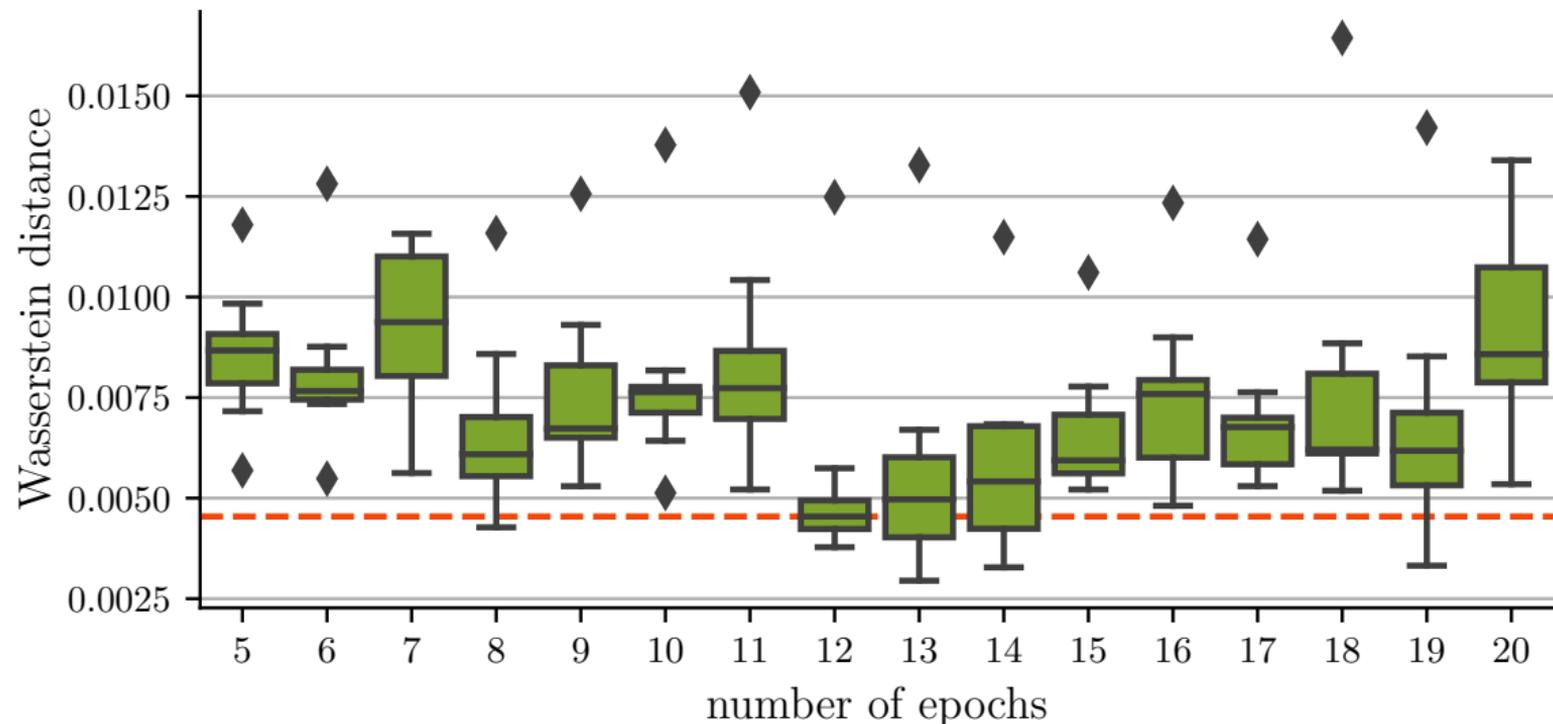
Hyperparametersuche – Konvergenzschwelle ϵ



Hyperparametersuche – Clusteranzahl J



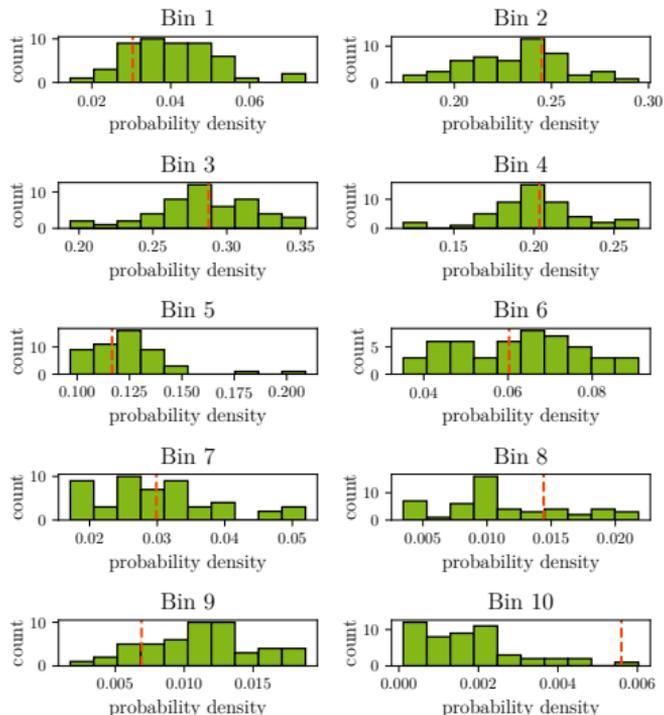
Hyperparametersuche – Epochenzahl



Bootstrapping

- Ziel: Schätze Unsicherheit der Entfaltung ab
- Vorgehen (iteriert):
 - Ziehe (mit Zurücklegen) Beispiele aus dem ursprünglichen Datensatz
 - Trainiere damit das Modell
 - Evaluiere jeweils auf den Beispielen, die nicht gezogen wurden
- Bestimme Median/Quantile

Bootstrapping – Verteilungen pro Bin



Vergleiche

■ Jäkel¹:

-  12 Bins
-  Ohne Under-/Overflow-Bins
-  Ohne adaptive Schrittweite
- Ähnliche Wasserstein-Distanz (0.0108 vs. 0.00879)
- Keine strikte Unimodalität der Konfidenzverteilungen

■ Haefs²:

-  Ohne Under-/Overflow-Bins
-  Ohne adaptive Schrittweite
-  Bias-Test anders herum
-  Bootstrapping nur auf den Test-Daten
- Etwas bessere Genauigkeit (42.7 % vs. < 39 %)
- Etwas besseres Spektrum für Energien $< 1 \times 10^5$ GeV
- Deutlich weniger Bias

¹Jäkel, „Ordinal Classification in DSEA“.