

## ML basiertes Klassifikationssystem und Expertensystem für Mikrometeoriten v1.7

Als PDF exportieren




Bild des Objekts hochladen / Upload object image

THMM57...6.jpg.png

Das Bild bleibt lokal im Browser und wird nicht an einen Server übertragen.



Schwellenwert für MM (in %)  (Standard: 50%. Bild gilt als MM, wenn die durchschnittliche P(MM) des Ensembles  $\geq$  Schwellenwert ist.)

Modellgruppe:  Vorverarbeitung:

• Service verbunden (v1.3.0)

ML-Klassifikation erfolgreich durchgeführt.

Automatische Klassifikation (ML)

ML-Klassifikation: Mikrometeorit (MM)-Kandidat.

Schwellenwert: 70% – Durchschnittliche P(MM) des Ensembles: 90.0%.

**Mikrometeorit (MM)**

Eigene Bewertung (Schwellenwert 70%): Durchschnittliche P(MM) = 90.0%

### Erklärung

7 von 7 Modellen (ConvNeXt, SwinV2, EffNetV2, DaViT, MaxViT, DINOv2, CLIP) bewerten dieses Bild mit einer Wahrscheinlichkeit P(MM) von 70% oder mehr für einen Mikrometeoriten. SwinV2, DaViT, MaxViT, DINOv2 sind sehr sicher (P(MM)  $\geq$  0.9). Der Durchschnitt des Ensembles liegt bei 90.0%, dein eingestellter Schwellenwert bei 70%.

Konfidenz: Hoch – die Modelle stimmen weitgehend überein (StdDev 0.01) und der Durchschnitt liegt deutlich über dem Schwellenwert.

```
C:\WINDOWS\system32\cmd x + v
2026-06-18 07:28:18 [INFO] ] mmservice: =====
2026-06-18 07:28:18 [INFO] ] mmservice: Service-Start Log-Verzeichnis: d:\Astronomie\Mikrometeoriten\MM_Docker\logs
2026-06-18 07:28:18 [INFO] ] mmservice: =====
2026-06-18 07:28:28 [INFO] ] mmservice: Service-Config geladen aus d:\Astronomie\Mikrometeoriten\MM_Docker\model_config.j
son
2026-06-18 07:28:28 [INFO] ] mmservice: Verfügbare Modellgruppen: ['normal', 'blur', 'rembg']
2026-06-18 07:28:28 [INFO] ] mmservice: Default-Gruppe: rembg
2026-06-18 07:28:28 [INFO] ] mmservice: Default-Vorverarbeitung: rembg
2026-06-18 07:28:28 [INFO] ] mmservice: Lade YOLO aus d:\Astronomie\Mikrometeoriten\MM_Docker\runs\detect\train3\weight
s\best.pt
[INIT] Verwende Device: cuda
2026-06-18 07:28:28 [INFO] ] mmservice: Lade Modellgruppe 'normal' aus d:\Astronomie\Mikrometeoriten\MM_Docker\checkpoi
nts
Lade Modellgruppe 'normal' aus d:\Astronomie\Mikrometeoriten\MM_Docker\checkpoints
convnext: geladen aus best_convnext_model.pt
swin2: geladen aus best_swin2_model.pt
efficientnetv2: geladen aus best_effnet_model.pt
davit: geladen aus best_davit_model.pt
maxvit: geladen aus best_maxvit_model.pt
dinov2: geladen aus best_dinov2_model.pt
clip: geladen aus best_clip_model.pt
2026-06-18 07:28:33 [INFO] ] mmservice: Lade Modellgruppe 'blur' aus d:\Astronomie\Mikrometeoriten\MM_Docker\checkpoint
s\blur
Lade Modellgruppe 'blur' aus d:\Astronomie\Mikrometeoriten\MM_Docker\checkpoints_blur
convnext: geladen aus best_convnext_model.pt
swin2: geladen aus best_swin2_model.pt
efficientnetv2: geladen aus best_effnet_model.pt
davit: geladen aus best_davit_model.pt
maxvit: geladen aus best_maxvit_model.pt
dinov2: geladen aus best_dinov2_model.pt
clip: geladen aus best_clip_model.pt
2026-06-18 07:28:37 [INFO] ] mmservice: Lade Modellgruppe 'rembg' aus d:\Astronomie\Mikrometeoriten\MM_Docker\checkpoi
ts_nobg
Lade Modellgruppe 'rembg' aus d:\Astronomie\Mikrometeoriten\MM_Docker\checkpoints_nobg
convnext: geladen aus best_convnext_model.pt
swin2: geladen aus best_swin2_model.pt
efficientnetv2: geladen aus best_effnet_model.pt
davit: geladen aus best_davit_model.pt
maxvit: geladen aus best_maxvit_model.pt
dinov2: geladen aus best_dinov2_model.pt
clip: geladen aus best_clip_model.pt
2026-06-18 07:28:42 [INFO] ] mmservice: Service bereit. Geladene Gruppen: ['normal', 'blur', 'rembg']
INFO: Started server process [13612]
INFO: Waiting for application startup.
INFO: Application startup complete.
INFO: Uvicorn running on http://0.0.0.0:8000 (Press CTRL+C to quit)
INFO: 127.0.0.1:59462 ~ "GET /service_info HTTP/1.1" 200 OK

0: 640x544 1 mikrometeorit_kandidat, 26.7ms
Speed: 27.1ms preprocess, 26.7ms inference, 11.6ms postprocess per image at shape (1, 3, 640, 544)
DEBUG: Gefundene Boxes: 1
DEBUG: Klasse 0.0 mit Konfidenz 0.78
DEBUG: YOLO hat mikrometeorit_kandidat erkannt: 0.7818788886070251
DEBUG: Mask-Blur erzeugt (Methode=yolo, ksize=31)
2026-06-18 07:29:09 [INFO] ] mmservice: rembg-Session geladen (Modell: u2net)
DEBUG: Background-Removal erzeugt
INFO: 127.0.0.1:56823 ~ "POST /mclassify HTTP/1.1" 200 OK
```

<https://www.waldhor.com/astronomie>

# Machine Learning für Amateurastronomen

Prof. Dr. Klemens Waldhör | 21.06.2026 | 28. Kleinplanetentagung VEGA-Sternwarte Haus der Natur

00

# Überblick Präsentation

Einführung



# Inhalt

**01 KI, ML, LLM**

**02 Machine Learning und Expertensysteme am Beispiel Mikrometeoriten**

**03 Astronomische Softwareentwicklung mit LLMs**

**04 Zusammenfassung**

**05a Anhang Beispielklassifikationen MM/NMM von Gerhard Grau**

**05b Publikumsfrage: Rost und Mikrometeoriten**

## Beruf

### Studium, Universität

- Informatik (1978 – 1983)
- Promotion (1984 – 1987)
- Assistent (1983 – 1986)

### Wirtschaft

- KI-Forschungsabteilung TA Triumph Adler AG (1986 – 1993)
- Eigene Unternehmen (1993 – heute)
- Geschäftsführer Krems Research (2004 – 2008)
- Dozent, Professor für Wirtschaftsinformatik FOM Hochschule (2008 – heute)
- 1. Vorsitzender TSV Roßtal
- Im Vorstand Altnürnberger Landschaft / Deutsch-Französischer Freundschaftskreis Roßtal

### Forschung

- Expertensysteme, Wissensrepräsentation, Erklärungskomponenten
- Benutzerschnittstellen
- Übersetzungstechnologie
- eTourismus
- AAL / Smart Watches / Smart Home
- LLM in Software Engineering, Projektmanagement und Programmierung

# Und Hobbyastronom

**Ab 14 Lebensjahr bis heute: Interesse an Astronomie**

**Ich sehe mich als beobachtenden Astrofotographen**

## Vereine

- Kepler Sternwarte Linz, VdS, Nürnberger Astronomische Gemeinschaft, Astromischer Arbeitskreis Salzkammergut, Signalgruppen

## Interessen

- Kometenfotografie

Supernova und Transienten-Fotografie

Software-Entwicklung für astronomische Anwendungen, insbesondere mit KI

## Webseite

<https://www.waldhor.com/astronomie>

## Ausrüstung

### Montierungen

- EQ6R Pro, ASI AM5, Star Adventurer, Celestron AVX mit NextStep-Steuerung
- OpenAstroTracker
- Teleskope  
RSA 8, Seestar S50, TS APO 72/432, 127/950, Newton 250/1000 mm Eigenbau, Newton 150/1500

### Kameras

- ASI2600MC, ASI1600 mit Filterrad, ASI294MM/MC, ASI178MM, ASI120MC
- Canon EOS 5D Mk II, AllSkyCam

### Steuerungen & Sonstiges

- ASI AIR & AIR Plus, Stellar Mate Pro, MGEN 2
- MLastrO SHG 700

# Astronomie Software im Laufe der Jahre

## Software & KI-Projekte

Direktzugriff auf meine browserbasierten Astronomie-Tools. Viele der Anwendungen wurden ganz oder teilweise mit KI-Unterstützung erstellt.

Vorbereitungswerkzeug  
für meine Beobachtungsnächte

**RA/DEC**  
Koordinaten umrechnen

**Breite/Höhe**  
Objekthöhe berechnen

**Tag/Nachtbogen**  
Sichtbarkeitsverlauf

**Objekt-Marathon**  
Beobachtungsnacht planen

**Beobachtungsliste**  
Objekte & Sichtbarkeit

**Mondzeiten**  
Bibliotheken vergleichen

**Kometenposition**  
RA/DEC per Horizons

**Kometen & Kleinplaneten**  
sichtbare Objekte

**Astro-Datenbank**  
Kataloge abfragen

**Astro Sampling**  
Pixel-Skala & Nyquist

**Grenzgröße**  
Optik & Sensor

**Sensor Analyzer**  
Hot-Pixel & RGB

**Vignettierung**  
Ausleuchtung prüfen

**Auflösung**  
Optik/Sensor bewerten

**ASIAIR Calibration**  
Guiding-Schritte

**Guiding-Kalibrierziele**  
Meridian & Dec 0°

**Supernova → ASTAP**  
deep\_sky.csv erzeugen

**Belichtungszeit**  
Polfehler berücksichtigen

**Weltzeituhr**  
Zeitvergleich

**Exoplanet Planner**  
Transite planen

**Smart-Telescope-Berater**  
regelbasiertes XSP

**Bildorientierung**  
Norden oben

**Mikrometeoriten**  
KI-Klassifikation

Webseite zum Klassifikationssystem  
für Mikrometeoriten

# Astronomie Software im Laufe der Jahre

## Software & KI-Projekte

Direktzugriff auf meine browserbasierten Astronomie-Tools. Viele der Anwendungen sind experimentelle Eigenentwicklungen und wurden ganz oder teilweise mit KI-Unterstützung erstellt.

**RA/DEC**  
Koordinaten umrechnen

**Breite/Höhe**  
Objekthöhe berechnen

**Tag/Nachtbogen**  
Sichtbarkeitsverlauf

**Objekt-Marathon**  
Beobachtungsnacht planen

**Beobachtungsliste**  
Objekte & Sichtbarkeit

**Mondzeiten**  
Bibliotheken vergleichen

**Kometenposition**

**Kometen & Kleinplaneten**  
sichtbare Objekte

**Astro-Datenbank**  
Kataloge abfragen

**Astro Sampling**  
Pixel-Skala & Nyquist

**Grenzgröße**  
Optik & Sensor

**Sensor Analyzer**  
Hot-Pixel & RGB

**Vignettierung**  
Ausleuchtung prüfen

**ASIAIR Calibration**  
Guiding-Schritte

**Guiding-Kalibrierziele**  
Meridian & Dec 0°

**Supernova -> ASTAP**  
deep\_sky.csv erzeugen

**Beleuchtungszeit**  
Polfehler berücksichtigen


**Weltzeituhr**  
Zeitvergleich

**Exoplanet-Planung**  
Transite planen

**Bildorientierung**  
Norden oben

**Mikrometeoriten**  
KI-Klassifikation

Webseite zur Generierung der Datei deep\_sky.csv zur Markierung von Transienten in ASTAP; PixinSight Datei kann auch generiert werden



# Astronomie Software im Laufe der Jahre

## Astronomischer Jahreskalender

<https://www.heartsome.de/ephem/>

2008-2021 Herbert Raab, Johannes-Kepler-Sternwarte Linz

2022 Portierung auf HTML/JavaScript durch Sven Schreier, Christopher Paal, Jens Herbst

2023 Weiterentwicklung durch Anton Eberle, Carina Dittl, Carsten Spitznagel, Christian Tabar, Daniel Schneider, Marco Weingart, Stefan Zeinz

im Rahmen der Lehrveranstaltung Anwendungsprojekt, Studiengang Wirtschaftsinformatik am FOM Hochschulzentrum in Nürnberg

Jahr:  Delta T:

Ort: 17, Friedrichstraße, Weikersdorf, Roßtal, Landkreis Fürth, Bayern, 90574, Deutschland

10.89°O 49.396°N Elevation:

Ort manuell auf Karte wählen

Zeit

☐ Weltzeit (UT)  
☐ Zonenzeit (MEZ)  
☒ Zonenzeit (MEZ/MESZ)

Ephemeriden

☐ detailliert  
☒ komprimiert

Positionen

☐ scheinbar  
☒ astrometrisch

Downloads

[Download TXT](#)  
[Download HTML](#)  
[Download PDF](#)

Rechnen

Planetensichtbarkeit Ereignisse Sonne Mond Merkur Venus Mars Jupiter Saturn Uranus Neptun Finsternisse Bedeckungen

Ringförmige Sonnenfinsternis am 17.02.2026

Die Finsternis ist von 17, Friedrichstraße, Weikersdorf, Roßtal, Landkreis Fürth, Bayern, 90574, Deutschland aus unsichtbar.

Globaler Verlauf:  
Größte Verfinsterung: 2:20 Ringförmigkeit am Ort 86.7°O, 64.7°S

Beginn der partiellen Finsternis: 10:56.4 MEZ  
Beginn der zentralen Finsternis: 12:48.3 MEZ  
Größte Verfinsterung: 13:11.9 MEZ  
Ende der zentralen Finsternis: 13:36.1 MEZ  
Ende der partiellen Finsternis: 15:27.7 MEZ

Totale Mondfinsternis am 03.03.2026

Die Finsternis ist von 17, Friedrichstraße, Weikersdorf, Roßtal, Landkreis Fürth, Bayern, 90574, Deutschland aus unsichtbar.

Größe der Finsternis im Kernschatten: 1.153

Eintritt in den Halbschatten: 09:44.0 MEZ  
Beginn der Freisichtigkeit: 10:28.2 MEZ  
Eintritt in den Kernschatten: 10:49.6 MEZ  
Beginn der Totalität: 12:03.9 MEZ  
Finsternismitte: 12:33.7 MEZ  
Ende der Totalität: 13:02.9 MEZ  
Austritt aus dem Kernschatten: 14:17.4 MEZ  
Ende der Freisichtigkeit: 14:39.1 MEZ  
Austritt aus dem Halbschatten: 15:23.3 MEZ

Totale Sonnenfinsternis am 12.08.2026

Die Finsternis ist von 17, Friedrichstraße, Weikersdorf, Roßtal, Landkreis Fürth, Bayern, 90574, Deutschland aus als partielle Verfinsterung größtenteils sichtbar.

Globaler Verlauf:  
Größte Verfinsterung: 2:18 Totalität am Ort 25.2°W, 65.2°N

Beginn der partiellen Finsternis: 17:34.2 MESZ  
Beginn der zentralen Finsternis: 19:00.1 MESZ  
Größte Verfinsterung: 19:45.9 MESZ  
Ende der zentralen Finsternis: 20:32.2 MESZ  
Ende der partiellen Finsternis: 21:58.0 MESZ

Lokaler Verlauf:  
Größte Verfinsterung: 0.898 (Bedeckung: 87.9%)

Beginn der partiellen Finsternis: 19:21.0 MESZ (11.3° W)  
Größte Verfinsterung: 20:14.1 MESZ (3.1° WNW)  
Sonnenuntergang bei Größe 0.514: 20:38 MESZ (WNW)

# Astronomie Software im Laufe der Jahre

## Objekt-Marathon Rechner

Mit dem Objekt-Marathon-Rechner lassen sich Beobachtungs- oder Fotografierrmarathons für verschiedene astronomische Objektlisten erstellen, z. B. für Messier-, NGC- oder Supernova-Objekte. Ein Objekt-Marathon bezeichnet dabei eine geplante Beobachtungsnacht, in der möglichst viele ausgewählte Himmelsobjekte in sinnvoller Reihenfolge beobachtet oder fotografiert werden. Die Anwendung unterstützt bei der Auswahl, zeitlichen Planung und Priorisierung der Objekte anhand ihrer Sichtbarkeit.

Geografische Breite

49.3977926

Geografische Länge

-10.8849103

Ortsuche

Roßtal, Landkreis Fürth, Ba

Startdatum

17.06.2026

Objektart

Messier

Enddatum

18.06.2026

Planparameter

Filter

#Filter Red, Clear, Green, Blue

Binning

#Binning 1,1,1,1

Anzahl Bilder

#Count 1,1,1,1

Intervall

#Interval 120,120,120,120

Wartezeit

#Waitfor 30

Koordinaten Ausgabe

☒

Berechnungs-basis

☐ Sonnenaufgang/untergang

☒ bürgerliche Dämmerung

☐ nautische Dämmerung

☐ astronomische Dämmerung

Grenzgröße

30

Minimale Höhe über Horizont

0

Projektion

mollweide

Objekt-Marathon berechnen

Graphbogen Darstellung

Parameter ein/ausblenden

[Sichtbare Marathonobjekte](#)

[Sonnenauf- und untergang](#)

[Beschreibung / Hilfe](#)

Liste sichtbarer Marathon-Objekte vom Mittwoch, 17. Juni 2026 bis Donnerstag, 18. Juni 2026

2026-06-17

17.6.2026, 22:08:44

M14, M30, M6, M7, M23, M20, M8, M21, M24, M16, M74, M18, M17, M28, M69, M25, M22, M70, M26, M11, M57, M54, M56, M45, M38, M55, M71, M27, M75, M36, M29, M37, M77, M72

18.6.2026, 04:26:12

98 (110)

Aufnahmedauer:

2940 s / 0.82 h

[Download Plan als Textdatei: plan\\_marathon17.6.2026, 22:08:44](#)

[Download Plan als ASI AIR Textdatei: plan\\_marathon17.6.2026, 22:08:44](#)

[Download Plan als Seestar Plan: plan\\_marathon17.6.2026, 22:08:44](#)

[Download Plan als virtualSky Textdatei: plan\\_marathon17.6.2026, 22:08:44](#)

[Detaillierte Tabelle](#)

M1, M35, M41, M42, M43, M46, M47, M48, M50, M78, M79, M93

| Datum   | Morgendämmerung         | Auf   | Trans | Unter | Abenddämmerung    |
|---------|-------------------------|-------|-------|-------|-------------------|
|         | Astr. Naut. Bürg.       |       |       |       | Bürg. Naut. Astr. |
| Jun. 17 | --:-- 03:23 04:26 05:09 | 13:17 | 21:25 | 22:08 | 23:11 --:-- MES2  |
| Jun. 18 | --:-- 03:23 04:26 05:09 | 13:17 | 21:25 | 22:09 | 23:12 --:-- MES2  |

Mittwoch, 17. Juni 2026 11:02:42

49.40N, 10.89O

Powered by LCOGT

21.06.2026

Machine Learning für Amateurastronomen - Kleinplanetentagung 2026 - Prof. Dr. Klemens Waldhör

9

# Astronomie Software im Laufe der Jahre

# Das KI Projekt Astronomische Beobachtungsliste

Die astronomische Beobachtungsliste zeigt – ähnlich wie ein Objekt-Marathon – die Sichtbarkeit verschiedener astronomischer Objekte im Verlauf der Nacht. Neben vordefinierten Listen wie Messier-, Caldwell- und Herschel-Objekten können auch eigene Objektlisten importiert werden. Unterstützt werden derzeit unter anderem Supernovae, Kometen, veränderliche Sterne und Near-Earth-Objekte. Eine Alpaca-basierte Teleskopsteuerung ist prototypisch integriert; sie erfordert je nach Systemumgebung gegebenenfalls den Start eines lokalen CORS-Servers.

# ASTRONOMISCHE BEOBACHTUNGSLISTE

Sichtbarkeit vom Beobachtungsort · Lokale Berechnung

[Katalog](#)

---

**TELESKOP**    **11:04:04**    Ortszeit Roßtal (UTC+2)    UTC: 09-04-04

---

**ORTSSUCHE**  
 [Suchen](#)

**GESPEICHERTE ORTE**  
 [✕](#)

**DATUM**  
 [📅](#)

**BREITE (°N)**

**LÄNGE (°O)**

**UTC-OFFSET [H]**

---

ICH UTC [H]  
 - Zeitzone - [Meine Zeit](#)

▶ BERECHNEN

---

Min. Max-Höhe: 
Suche: 
Sortierung: [Kulmination](#) | [Max. Höhe](#) | [Helligkeit](#) | [Name](#) | [MondZ.](#)
☒ Nur nicht fotografiert

---

SETUP  
 Teleskop:  Kamera:  f/S: 0 - 2.39"/px [Limag](#)

---

**KATALOG**  
 [! Katalog laden](#) [✕ Entfernen](#)

**FOTOS:** [! Speichern \(J50W\)](#) [! Laden \(J50W\)](#) [✕ Alle zurücksetzen](#) 0 fotografiert [EXPORT: AstAix CSV](#)

---

[SkySafari .skylist](#) [Voyager CSV](#) [Höhenkurven](#) [@ Slow-Reihenfolge](#)

[Notizen sichern](#) [Notizen laden](#) [▲ Horizont](#) [🗺️ Kärtchen](#) [↓ J50W](#)

---

**KOMETEN**  
☒ JPL:   Vmag max:  Min.Höhe:  [JPL Abfragen](#)

AERITH: [Kometen laden](#) MAG MAX:

---

**NEA**  
☒ NEA: [NEA-Vorbeiflüge laden](#) Fenster:  Max. Dist:  Gruppe:

---

**TRANSIENTE**  
☒ SN: [Supernovae laden](#) Ab Datum:  Vmag max:

☒ TNS: [TNS laden](#) TAG:  MAG MAX:  TYP:  BOT-ID:  BOT-NAME:  API-KEY:

---

**VERÄNDERLICHE**  
☒ VSX: [Veränderliche laden](#) Radius ("):  Max. mag:  Typ:

---

STANDORT 49.4000°N 10.8670°O  
 AMMERUNG 22:09 UTC+2  
 MOND 🌑 11% 180:13 123:51 ▲15°  
 SICHTBAR 99 stehbar  
 ESAMT 110 - Katalog  
 JPL -  
 SN -  
 NEA -  
 VSX -  
 FOTOGRAFIERT 0 / 57

| # | NAME                            | TYP              | KON | MAG | GRÖSSE | REKTASZENSION | DEKLINATION    | HÖHENWINK | MAX HÖHE | AUFANG | UNTERGANG | KULMINATION ▲ | MONDZ. | FOT |
|---|---------------------------------|------------------|-----|-----|--------|---------------|----------------|-----------|----------|--------|-----------|---------------|--------|-----|
| ☐ | <b>M 107</b> <a href="#">UP</a> | Globular Cluster | Oph | 7.9 | 480"   | 16h 32m 31.9s | -13° 03' 13.0" | +22.5°    | 27.5°    | 19:04  | 05:00     | 00:04         | 123%   | -   |
| ☐ | <b>M 13</b> <a href="#">UP</a>  | Globular Cluster | Her | 5.8 | 1020"  | 16h 41m 41.4s | +36° 27' 37.0" | +64.0°    | 77.1°    | 14:13  | 10:10     | 00:13         | 101%   | -   |
| ☐ | <b>M 12</b> <a href="#">UP</a>  | Globular Cluster | Oph | 6.7 | 900"   | 16h 47m 14.2s | -01° 56' 54.0" | +31.5°    | 30.7°    | 18:25  | 06:08     | 00:19         | 122%   | -   |
| ☐ | <b>M 10</b> <a href="#">UP</a>  | Globular Cluster | Oph | 6.6 | 840"   | 16h 57m 09.1s | -04° 05' 50.0" | +20.5°    | 36.5°    | 18:45  | 06:08     | 00:28         | 125%   | -   |
| ☐ | <b>M 62</b> <a href="#">UP</a>  | Globular Cluster | Oph | 6.5 | 840"   | 17h 01m 12.6s | -30° 06' 45.0" | +4.2°     | 10.5°    | 21:19  | 03:42     | 00:32         | 132%   | -   |
| ☐ | <b>M 19</b> <a href="#">UP</a>  | Globular Cluster | Oph | 6.8 | 840"   | 17h 02m 37.7s | -26° 16' 05.0" | +7.7°     | 14.3°    | 20:51  | 04:13     | 00:34         | 132%   | -   |
| ☐ | <b>M 92</b> <a href="#">UP</a>  | Globular Cluster | Her | 6.4 | 720"   | 17h 17m 07.4s | +43° 00' 11.0" | +62.0°    | 83.7°    | =      | =         | 00:48         | 102%   | -   |

# Astronomie Software im Laufe der Jahre

## Astro-Limit Optics Sensor Analyzer Pro

Präzise Analyse der stellaren Grenzgröße basierend auf Optik, Sensorleistung und lokaler Lichtverschmutzung.

Astro-Limit Optics Sensor Analyzer Pro (v1.7) - Stacking Edition

JSON laden

Konfig Export

Hilfe / Autor

Optik & Standort

Celestron RASA 8

203400

Standort (Bortle)

B5: Vorstadt (6.2 mag)

Sensor

ASI2600MM/MC-Pro

QE %

91

Pixel µm

3,76

Temp °C

20

Analyse

Belichtungszeit (s)

600

Anzahl Bilder (Stacks)

1

Grafik & PNG Export

| ZEIT (GES.)      | GRENZGRÖSSE (MAG) | VS. AUGE   | SAMPLING ("/PX) |
|------------------|-------------------|------------|-----------------|
| 1s (1x1s)        | 16.01             | 12.183x    | 1.94            |
| 10s (1x10s)      | 18.49             | 119.487x   | 1.94            |
| 30s (1x30s)      | 19.64             | 344.297x   | 1.94            |
| 60s (1x60s)      | 20.34             | 652.203x   | 1.94            |
| 300s (1x300s)    | 21.77             | 2.442.508x | 1.94            |
| 600s (1x600s)    | 22.30             | 3.970.332x | 1.94            |
| 600s (1x600s)    | 22.30             | 3.970.332x | 1.94            |
| 1.200s (1x1200s) | 22.78             | 6.205.241x | 1.94            |

# Astronomie Software im Laufe der Jahre

## Experiment mit Studenten: Aufgabe

- Erstellung einer Webanwendung gemäß Beschreibung der Aufgabe
- Studenten hatten keine Erfahrung / Berührungspunkte zur Astronomie
- Struktur der Gruppen
  - Mit Informatikerfahrung
    - ~ 3 Gruppen a 4 Studenten Business Analytics (Master, Online)
    - 8 Gruppen a 2-3 Studenten: Big Data & Data Science (Wirtschaftsinformatik)
  - Ohne Informatikerfahrung
    - 2 Gruppen a 2/3 5 Studenten: Künstliche Intelligenz und Agentensysteme (KI und Psychologie, tlw. Absolventen Gymnasium, keine Programmiererfahrung)

KI und Programmieren

Prof. Dr. Klemens Waldhör

**Sterne, Code und Qualität: LLMs im Härtestest der Softwareentwicklung**

Sie sollen eine Webbasierte astronomische Anwendung erstellen. Ziel soll sein die Position eines astronomischen Objektes in Höhe und Breite für eine beliebige Zeit und Datum und Ort ermittelt werden.

**Eingaben:**

- a) Objekt mit Rektaszension und Deklination

Gültige Formate: Sie können die Koordinaten flexibel eingeben.

- Rektaszension Beispiele: 18h 53m 35s, 18:53:35 oder als Dezimalwert 18.89.
- Deklination Beispiele: +33° 01' 45", +33 01 45 oder als Dezimalwert 33.02. Ein negatives Vorzeichen (-) ist für Objekte auf der südlichen Hemisphäre erforderlich.
- b) Uhrzeit und Datum in lokaler Zeit.
- c) Ort entweder als Ortsname oder als Länge und Breite.

**Ausgabe:**

- a) Position des Objektes in Höhe und Breite in Grad z

**Beispielobjekte**

| Objekt                    | Rektaszension   | Deklination     |
|---------------------------|-----------------|-----------------|
| M31                       | 00h 42m 44,3s   | +41° 16' 09"    |
| Wega                      | 18h 36m 56,336s | +38° 47' 01,29" |
| Kleine Magellansche Wolke | 00h 52m 44,8s   | -72° 49' 43"    |

**Ort:** Nürnberg (Breite ≈ 49.45° N, Länge ≈ 11.08° E)

**Ergebnis**

| Datum      | Uhrzeit | Objekt                    | Azimut | Höhe   |
|------------|---------|---------------------------|--------|--------|
| 17.09.2025 | 23:34   | M31                       | 91°24' | 61°45' |
| 04.05.2025 | 03:12   | M31                       | 42°34' | 15°07' |
| 17.09.2025 | 23:34   | Wega                      |        |        |
| 04.05.2025 | 03:12   | Wega                      |        |        |
| 17.09.2025 | 23:34   | Kleine Magellansche Wolke |        |        |
| 04.05.2025 | 03:12   | Kleine Magellansche Wolke |        |        |



ÜbungSterne

1

# Astronomie Software im Laufe der Jahre

## Experiment mit Studenten: Ergebnisse

- In den 13 Gruppen wurden 12 Web-Anwendungen in drei unterschiedlichen Lehrveranstaltungen entwickelt
  - 2 Gruppen kamen zu gar keinem Ergebnis
  - Problem mit Verständnis der Aufgabe
- 7 funktional erfolgreiche Implementierungen
  - Schnellste Entwicklung: 2 Minuten
- Eingesetzte LLMs
  - 8 x ChatGPTso5
  - 1 x GitHub CoPilot
  - 1 x Gemini
- Prompts
  - Manuell erstellt aus Aufgabenbeschreibung
  - Mit PDF als Spezifikation an LLM
- Nur zwei Gruppen kamen zu gar keinem Ergebnis
- GUI: auch hier entstehen ansprechende und funktionale Oberflächen

 **Sterne, Code und Qualität**

Berechne die Position eines astronomischen Objektes (Azimut & Höhe)

Objekt auswählen:

M31 (Andromedagalaxie) ▾

Rektaszension (z. B. 00h 42m 44.3s):

00h 42m 44.3s

Deklination (z. B. +41° 16' 09"):

+41° 16' 09"

Breitengrad (°):

49,45

Längengrad (°):

11,08

Datum & Uhrzeit (lokal):

17.09.2025 23:34 📅

Berechnen & hinzufügen

| Datum      | Uhrzeit | Objekt | Azimut (°) | Höhe (°) |
|------------|---------|--------|------------|----------|
| 2025-09-17 | 23:34   | M31    | 91.79      | 61.73    |

01

**KI, ML, LLM**

**Kurzeinführung**

# Künstliche Intelligenz

## Klassische KI

**Klassische bzw. symbolische KI** basiert auf der expliziten Darstellung von Wissen. Objekte, Begriffe und Beziehungen werden dabei als Symbole beschrieben und mit Hilfe logischer Regeln verarbeitet.

Die eigentliche Intelligenz entsteht durch Schlussfolgerungen, also durch Inferenz über dieses formal abgebildete Wissen. Dieses Wissen wird in der Regel von Menschen erarbeitet und anschließend in ein KI-System übertragen.

Ziel ist es, menschliches Problemlösen, Schließen und Denken durch Computer nachzuahmen. Typische Beispiele sind logische Knobelaufgaben oder frühe Expertensysteme.

## Machine Learning , Konnektionistische KI


**Machine Learning** basiert auf dem Lernen aus Daten, statt ausschließlich durch feste Regeln programmiert zu werden.

Das Modell erkennt Muster, Zusammenhänge und Strukturen anhand vieler Beispiele und verbessert seine Leistung durch Training.

Durch das Training entsteht ein **ML-Modell**, das die gelernten Muster und Zusammenhänge speichert und anschließend auf neue, unbekannte Daten anwenden kann.

Eine wichtige Spezialisierung ist die **konnektionistische KI**, die sich an der Funktionsweise biologischer Nervensysteme orientiert. Besonders künstliche neuronale Netze passen dabei ihre internen Gewichtungen an und ermöglichen Anwendungen wie Bild- und Spracherkennung, Klassifikation, Prognosen oder Entscheidungsunterstützung.

# Entwicklung der Künstlichen Intelligenz



KI entwickelte sich in Wellen – neue Methoden wurden jeweils durch Daten, Rechenleistung und Modellarchitekturen beschleunigt.

# Künstliche Intelligenz

## Expertensystem

**Expertensysteme** sind KI-Systeme, die Fachwissen eines bestimmten Anwendungsbereichs nachbilden und für Entscheidungen oder Empfehlungen nutzen.

Das Wissen wird dabei meist von menschlichen Expertinnen und Experten erhoben und in Form von Regeln, Fakten und Schlussfolgerungsmechanismen im System abgelegt.

Auf dieser Grundlage kann das System konkrete Fälle analysieren, Fragen beantworten oder Handlungsempfehlungen geben.

Expertensysteme waren besonders in der klassischen KI bedeutsam, zum Beispiel in der Medizin, Diagnostik, Technik oder Fehleranalyse.

## Neuronales Netz

Ein **neuronales Netz** ist ein Machine-Learning-Modell, das aus miteinander verbundenen künstlichen Neuronen besteht.

Diese sind meist in Schichten organisiert: Eingabeschicht, eine oder mehrere verborgene Schichten und Ausgabeschicht.

Beim Training werden die Gewichte der Verbindungen zwischen den Neuronen angepasst, sodass das Netz Muster in Daten erkennen und für neue Fälle nutzen kann.

Neuronale Netze eignen sich besonders für komplexe Aufgaben wie Bildklassifikation, Spracherkennung, Textverarbeitung oder Prognosen.


# Training von Machine Learning Modelle

## Allgemeiner Trainings/Validierungs/Test Prozess

Mit den Trainingsdaten lernt das ML-Modell.

Mit den Validierungsdaten wird seine Leistung überprüft und durch Anpassung der Hyperparameter verbessert.

Die Testdaten werden erst am Ende genutzt, um das finale Modell unabhängig und möglichst objektiv zu bewerten.



# Training von ML Modellen

## n-Fold Kreuzvalidierung

Cross-Validation ist ein Verfahren, bei dem die verfügbaren Daten mehrfach in Trainings- und Testdaten aufgeteilt werden, um die Leistung eines ML-Modells robuster zu bewerten. Besonders häufig ist die k-fache Cross-Validation, bei der das Modell k-mal trainiert und getestet wird, wobei jedes Teilstück der Daten einmal als Testmenge dient.



Qualitätsmaßstäbe

Konfusionsmatrix

Eine Konfusionsmatrix zeigt, wie gut ein Klassifikationsmodell arbeitet, indem sie die tatsächlichen Klassen mit den vom Modell vorhergesagten Klassen vergleicht. Am Beispiel der Mikrometeoriten-Klassifikation gibt es zwei Klassen: MM = Mikrometeorit und NMM = kein Mikrometeorit.

|                 | Modell sagt MM                 | Modell sagt NMM        |
|-----------------|--------------------------------|------------------------|
| Tatsächlich MM  | richtig erkannt (TP)           | Übersehen (FN)         |
| Tatsächlich NMM | fälschlich als MM erkannt (FP) | richtig abgelehnt (TN) |

Die vier Felder bedeuten:

- True Positive (TP): Ein echter Mikrometeorit wird korrekt als MM erkannt.
- False Positive (FP): Ein Nicht-Mikrometeorit wird fälschlich als MM eingestuft.
- False Negative (FN): Ein echter Mikrometeorit wird übersehen.
- True Negative (TN): Ein Nicht-Mikrometeorit wird korrekt als NMM erkannt.

Viele False Positives bedeuten, dass das System zu viele falsche Kandidaten meldet.

Viele False Negatives bedeuten, dass echte Mikrometeoriten übersehen werden.

# Qualitätsmaßstäbe

## Accuracy

Accuracy gibt an, wie viele Objekte insgesamt korrekt klassifiziert wurden – unabhängig davon, ob es sich um MM oder NMM handelt.

## Precision

Bei der Klassifikation von Mikrometeoriten beschreibt **Precision**, wie viele der vom Modell als Mikrometeorit erkannten Objekte tatsächlich Mikrometeoriten sind. Eine hohe Precision bedeutet also: Wenn das System „MM“ sagt, liegt es meistens richtig.

## Recall

**Recall** beschreibt dagegen, wie viele der tatsächlich vorhandenen Mikrometeoriten vom Modell auch gefunden werden. Eine hohe Recall bedeutet: Es werden möglichst wenige echte Mikrometeoriten übersehen.

## F-Score

Der **F-Score** fasst Precision und Recall zu einem gemeinsamen Wert zusammen und ist besonders hilfreich, wenn beide Aspekte gleichzeitig bewertet werden sollen.

## False-Positive-Rate FPR für MM

Ist der Anteil der NMM, die fälschlich als MM eingestuft werden. Eine niedrige False-Positive-Rate ist wichtig, damit möglichst wenige irdische Partikel irrtümlich als Mikrometeoriten bewertet werden.

Sh. auch <https://www.waldhor.com/datascience/roc.html>


## Beispiele:

Es gibt 20 echte Mikrometeoriten (MM) und 100 echte Nicht-Mikrometeoriten (NMM) in einer Probe. Das Modell erkennt 25 Objekte als Mikrometeoriten. Davon sind 15 tatsächlich Mikrometeoriten, 10 sind fälschlich erkannte Nicht-Mikrometeoriten. Von den 20 echten Mikrometeoriten werden 5 übersehen.

| Maßzahl   | Formel                                                    | Ergebnis |
|-----------|-----------------------------------------------------------|----------|
| Accuracy  | $(TP + TN) / (TP + TN + FP + FN)$                         | 87,5 %   |
| Precision | $TP / (TP + FP)$                                          | 60,0 %   |
| Recall    | $TP / (TP + FN)$                                          | 75,0 %   |
| F1-Score  | $2 \times Precision \times Recall / (Precision + Recall)$ | 66,7 %   |
| FPR       | $FP / (FP + TN)$                                          | 10,0 %   |

Das Modell erkennt 75 % der echten Mikrometeoriten, aber nur 60 % der als Mikrometeorit markierten Objekte sind tatsächlich Mikrometeoriten. Die False-Positive-Rate von 10 % bedeutet, dass 10 % der echten Nicht-Mikrometeoriten fälschlich als Mikrometeoriten eingestuft werden.

Neuronales Netz



### Neural Networks

©2016 Fjodor van Veen - asimovinstitute.org

- Backfed Input Cell
- Input Cell
- Noisy Input Cell
- Hidden Cell
- Probabilistic Hidden Cell
- Spiking Hidden Cell
- Output Cell
- Match Input Output Cell
- Recurrent Cell
- Memory Cell
- Different Memory Cell
- Kernel
- Convolution or Pool

Perceptron (P)    Feed Forward (FF)    Radial Basis Network (RBF)    Deep Feed Forward (DFF)


Recurrent Neural Network (RNN)    Long / Short Term Memory (LSTM)    Gated Recurrent Unit (GRU)


Auto Encoder (AE)    Variational AE (VAE)    Denoising AE (DAE)    Sparse AE (SAE)

Markov Chain (MC)    Hopfield Network (HN)    Boltzmann Machine (BM)    Restricted BM (RBM)    Deep Belief Network (DBN)

Neuronales Netz

Transferfunktion:  $z = \sum_i w_i x_i + b$     Aktivierungsfunktion:  $\hat{y} = f(z)$





**Automatische Klassifikation (ML)**  
**ML-Klassifikation:** Mikrometeorit (MM)-Kandidat.  
Schwellenwert: 70% – Durchschnittliche P(MM) des Ensembles: 94.3%.

**Mikrometeorit (MM)**  
Eigene Bewertung (Schwellenwert 70%): Durchschnittliche P(MM) = 94.3%

**Erklärung**  
7 von 7 Modellen (ConvNeXt, SwinV2, EffNetV2, DaViT, MaxViT, DINOv2, CLIP) bewerten dieses Bild mit einer Wahrscheinlichkeit P(MM) von 70% oder mehr für einen Mikrometeoriten. SwinV2, EffNetV2, DaViT, MaxViT, DINOv2, CLIP sind sehr sicher (P(MM) ≥ 0.9). Der Durchschnitt des Ensembles liegt bei 94.3%, dein eingestellter Schwellenwert bei 70%.

**Konfidenz:** Hoch – die Modelle stimmen weitgehend überein (StdDev 0.08) und der Durchschnitt liegt deutlich über dem Schwellenwert.


**Mikrometeorit-Analyse (V4)**  
YOLO hat mikrometeorit kandidat erkannt: 0.9198314547538757

**Sicher (Einstimmig MM)**

**Ergebnis: MM** (Schwellenwert 70%)

| Modell              | P(MM)        |
|---------------------|--------------|
| ConvNeXt            | 0.760        |
| SwinV2              | 1.000        |
| EffNetV2            | 1.000        |
| DaViT               | 1.000        |
| MaxViT              | 0.943        |
| DINOv2              | 0.954        |
| CLIP                | 0.940        |
| <b>Durchschnitt</b> | <b>0.943</b> |

Modell-Varianz (StdDev): 0.079



02

# Machine Learning und Expertensysteme

## Am Beispiel Mikrometeoritenerkennung

# Mikrometeoriten

## Definition

Mikrometeoriten (MM) sind kleine Staubfragmente aus dem Sonnensystem, ev. auch aus dem interstellaren Raum, in Sandkorngröße, die noch aus der Zeit der Entstehung unseres Sonnensystems stammen. Ihre Größe beträgt einige Mikrometer bis wenige Millimeter ( $\emptyset$  0,1-0,5 mm).

Sie entstehen durch u.a. durch Kollisionen im Asteroidengürtel. Wenn diese Partikel die Erde auf ihrem Weg kreuzen, heizen sie sich beim Weg durch die Erdatmosphäre je nach Eintrittswinkel unterschiedlich stark auf und werden in kürzester Zeit abgebremst. Dabei können sie aufschmelzen und ihre Form verändern.

## Forschung

Gefunden wurden MMs zuerst in der Antarktis. Man schätzt, dass etwa 50-100 MMs pro Jahr und  $\text{m}^2$  auf der Erde auftreffen. Bis vor 20 Jahren war Konsens in der Wissenschaft, dass man MMs nicht in urbanen Umgehungen finden kann.

Bis Jon Larsen (Jazz-Musiker, der Geologe werden wollte) durch Zufall auf das Thema stieß und systematisch zu suchen begann. Er konnte dann als erster einen MM auf Dächern etc. nachweisen.



<https://www.facebook.com/photo/?fbid=263037438615126&set=g.2725815960821095>



<https://www.facebook.com/photo/?fbid=3726193244128023&set=g.2725815960821095>

# Mikrometeoriten

## Literatur

Genge, M.J., Engrand, C., Gounelle, M., Taylor, S. 2008. The classification of micrometeorites. *Meteoritics & Planetary Science* 43, 3, 497–515.

Hasse, T. 2025. Urbane Mikrometeoriten erkennen und unterscheiden. Amazon KDP, Berlin ISBN: 979-8269856568.

**Hasse, T., Waldhör, K., Gärtner, P. 2022. Mikrometeorite Sternenstaub für jeden. *Sterne und Weltraum* 60, 4, 80–87.**

Larsen, J. 2018. Auf der Jagd nach Sternenstaub. Die faszinierende Welt der Mikrometeoriten und ihrer irdischen Doppelgänger. GeraMond, München.

Larsen, J. 2019. Sternenjäger. Meine Suche nach dem Stoff, aus dem das Universum gemacht ist. Benevento, Salzburg, München.

Waldhör, K. 2023. Mikrometeoriten und ihre Erkennung. *Regiomontanus Bote* 36, 3, 8–11.

## Webseiten

Hasse, T.: <https://www.micrometeorites.org/>

Facebook: <https://www.facebook.com/groups/>

Larsen, J.:  
<https://www.patreon.com/cw/ProjectStardust826mikrometeoriten>

Zauner, M. <https://www.dielichterdernacht.at/>

# Mikrometeoriten

## Studentische Forschungsarbeiten

Dittl, C., Smith, S., Spitznagel, C., and Weingart, M. 2021. Erkennung von Mikrometeoriten mit Hilfe von Künstlicher Intelligenz. Seminararbeit, FOM Hochschule für Oekonomie & Management.

Gruber, M., Kotz, T., Kröhnert, T., Regnet, M., and Sandner, S. 2022. Anwendungsprojekt: Webseite/App Mikrometeoriten klassifizieren. Seminararbeit, FOM Hochschule.

Merkel, M., and Voigt, R. 2021. *Bildverarbeitung/analyse - Mikrometeoriten erkennen*. Seminararbeit, FOM Hochschule.


Merkel, M., and Voigt, R. 2022. *Projekt „MMClass“ Optimierung der Klassifikation von Mikrometeoriten mittels KI*. Projektarbeit, FOM Hochschule für Oekonomie & Management.

Voigt, R. 2023. *Automatische Erkennung von Mikrometeoriten mittels künstlicher Intelligenz: Prototyping einer State-of-the-Art Architektur*. Masterthesis, FOM Hochschule.

# Mikrometeoriten


## Problem

Vor allem für Anfänger sind MMs schwer zu erkennen.  
Funde müssen oft durch Experten verifiziert werden  
(weltweit 3-5!, Jon Larsen, Thilo Hasse (D), ...)




## Fotografie

Fotografieren erfordert spezielle Ausrüstung (Stacking)  
Professionelle Aufnahmeumgebung




Mikrometeoriten



CRISP-DM Modell

Der methodische Orbit: CRISP-DM im Weltraum-Labor




CRISP-DM PROCESS MODEL – ORBITAL ADAPTATION v1.0

NotebookLM

# CRISP-DM Modell: Business Understanding

## PHASE 1: BUSINESS UNDERSTANDING

### Staub aus der Geburtsstunde unseres Sonnensystems



#### Der Ursprung

Mikrometeoriten (MM) sind Fragmente aus dem Asteroidengürtel oder von Kometen, die extremste Temperaturen bei den Temperaturen beim Eintritt in die Erdatmosphäre durchlaufen.

#### Die Menge

Etwa 50–100 MMs fallen pro Jahr und Quadratmeter auf die Erde.

#### Das Business-Problem

Die manuelle Identifikation unter dem Mikroskop ist zeitaufwendig, teuer und erfordert jahrelange Expertise, um MMs von industriellem Schmutz zu unterscheiden.


CRISP-DM Modell: Business Understanding

PHASE 1: BUSINESS UNDERSTANDING

Die visuelle Täuschung: Kosmisch oder Irdisch?




manmade-Set24a-40\_61B14\_40-1-0,3-8lm-1a2i-33c2\_relS.jpg.png



**Die menschliche Grenze:** Selbst für erfahrene Sammler ist die optische Trennung fehleranfällig. Ohne teure Isotopenuntersuchungen im Labor bleibt nur die visuelle Inspektion – der perfekte Anwendungsfall für Bilderkennungs-KI.

NotebookLM

CRISP-DM Modell: Data Understanding



# CRISP-DM Modell: Data Understanding

| Modell         | N  | Ø Std. P(MM) | Max. Std. | Ø Spannweite | Flip-Rate | Ø P(MM) Original | P(MM) maskiert | Bewertung  | Ø Std. P(MM)    | Bewertung  | Bedeutung                                                       |
|----------------|----|--------------|-----------|--------------|-----------|------------------|----------------|------------|-----------------|------------|-----------------------------------------------------------------|
| CLIP           | 33 | 0.0836       | 0.2841    | 0.2457       | 0.24      | 0.7787           | –              | auffällig  | < 0.03          | robust     | Sehr stabile Bewertung trotz unterschiedlicher Hintergründe     |
| ConvNeXt       | 33 | 0.0866       | 0.1352    | 0.2185       | 0.61      | 0.6902           | –              | auffällig  |                 |            |                                                                 |
| DaViT          | 33 | 0.1554       | 0.4747    | 0.4039       | 0.45      | 0.5899           | –              | kritisch   | 0.03 bis < 0.07 | akzeptabel | Geringe bis moderate Hintergrundabhängigkeit                    |
| DINOv2         | 33 | 0.0670       | 0.2237    | 0.1946       | 0.18      | 0.7723           | –              | akzeptabel |                 |            |                                                                 |
| EfficientNetV2 | 33 | 0.1623       | 0.3925    | 0.4752       | 0.48      | 0.4730           | –              | kritisch   | 0.07 bis < 0.12 | auffällig  | Der Hintergrund hat einen sichtbaren Einfluss auf die Bewertung |
| MaxViT         | 33 | 0.0227       | 0.2663    | 0.0620       | 0.06      | 0.9392           | –              | robust     |                 |            |                                                                 |
| SwinV2         | 33 | 0.1683       | 0.3865    | 0.4924       | 0.52      | 0.5283           | –              | kritisch   | ≥ 0.12          | kritisch   | Starke Hintergrundabhängigkeit des Modells                      |
|                |    |              |           |              |           |                  |                |            |                 |            |                                                                 |



Die Tabelle zeigt, wie stark sich die **vorhergesagte Wahrscheinlichkeit für „Mikrometeorit“** durch **unterschiedliche Hintergründe** verändert. Besonders robust ist MaxViT, da die mittlere Standardabweichung sehr niedrig ist und sich das Klassifikationsergebnis nur selten ändert. DINOv2 ist noch akzeptabel, während DaViT, EfficientNetV2 und SwinV2 eine deutliche Abhängigkeit vom Hintergrund zeigen.

| Kennzahl         | Bedeutung                                                                                             | Interpretation                                                                            |
|------------------|-------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------|
| N                | Anzahl der getesteten Bilder                                                                          | Gibt an, auf wie vielen Bildern die Robustheitsanalyse basiert                            |
| Ø Std. P(MM)     | Durchschnittliche Standardabweichung der MM-Wahrscheinlichkeit über verschiedene Hintergrundvarianten | Je kleiner der Wert, desto stabiler reagiert das Modell auf Hintergrundänderungen         |
| Max. Std.        | Größte beobachtete Standardabweichung über alle Bilder                                                | Zeigt den ungünstigsten Einzelfall, also den stärksten Einfluss eines Hintergrundwechsels |
| Ø Spannweite     | Durchschnittliche Differenz zwischen höchster und niedrigster P(MM) pro Bild                          | Beschreibt, wie stark die Modellbewertung im Mittel schwankt                              |
| Flip-Rate        | Anteil der Bilder, bei denen ein Hintergrundwechsel das Urteil ändert                                 | Ein hoher Wert bedeutet, dass das Modell häufig zwischen MM und NMM wechselt              |
| Ø P(MM) Original | Durchschnittliche MM-Wahrscheinlichkeit auf den Originalbildern                                       | Zeigt, wie stark das Modell die Originalbilder im Mittel als Mikrometeoriten bewertet     |
| P(MM) maskiert   | Durchschnittliche MM-Wahrscheinlichkeit, wenn das Objekt verdeckt wurde                               | Dient als Hinweis, ob das Modell möglicherweise den Hintergrund statt des Objekts nutzt   |
| Bewertung        | Einordnung der Hintergrundrobustheit                                                                  | Fasst die Stabilität des Modells als robust, akzeptabel, auffällig oder kritisch zusammen |

# CRISP-DM Modell: Data Preparation

## PHASE 3: DATA PREPARATION

### Der optische Flaschenhals: Focus Stacking



#### Das optische Problem

3D-Objekte im Mikrometer-Bereich besitzen eine extrem geringe Tiefenschärfe. Nur Bruchteile sind im Mikroskop fokussiert.

#### Die Stacking-Lösung

Hunderte Einzelfotos mit leicht verschobenem Fokus werden algorithmisch zu einem durchgehend scharfen Bild verschmolzen.

#### Die KI-Hürde

Modelle, die nur auf perfekten Stacking-Bildern trainiert werden, scheitern oft an den leicht unscharfen Fundbildern normaler Hobby-Sucher.

CRISP-DM Modell: Data Preparation

PHASE 3: DATA PREPARATION

Die Preprocessing-Pipeline:  
Vom Rohbild zum Tensor



1. Originalbild

Das rohe Mikroskopbild mit Text und Maßstäben.

2. Konturerkennung

Ein Rahmen isoliert das physische Objekt vom Hintergrund.

3. Freistellung

Entfernung von Hintergrundrauschen und Text.

4. Normalisierung

Auffüllen mit Weißraum (5% Padding) auf exakt 141x141 Pixel.

5. Augmentation

Rotation und Spiegelung zur künstlichen Vervielfachung des knappen Datensatzes.

# CRISP-DM Modell: Data Preparation



Original (symbolisch)



Bluring



Hintergrund entfernen  
einheitlich weiß






Bild beschneiden


THMM573\_20-1,6\_0,4sec\_11lm\_2i\_62C\_1600x1600 (126).jpg.png




CONVNEXT




SWINV2




EFFNET




DAVIT



MAXVIT



DINOv2



CLIP

Sicht verschiedener ML- Modelle


# CRISP-DM Modell: Modelling

## PHASE 4: MODELING

### Ansatz I: Die Black Box – Maschinelles Lernen

#### Technologie:

- maxvit
- dinov2
- clip
- davit
- efficientnetv2
- convnext
- swinv2



**Mechanik:** Das Netzwerk lernt selbstständig Filter und Faltungen. Es erkennt abstrakte Muster (Kanten, Helligkeiten, Strukturen), ohne dass diese explizit programmiert wurden.

**Zielsetzung:** >90% Klassifizierungssicherheit.

## CRISP-DM Modell: Modelling

### Modelle im Ensemble zur MM-Klassifikation

Für die Klassifikation von Mikrometeoriten werden mehrere unterschiedliche Bildmodelle eingesetzt. Die Modelle analysieren dasselbe Bild aus verschiedenen Perspektiven und liefern jeweils eine Wahrscheinlichkeit dafür, ob es sich um einen Mikrometeoriten handelt. Durch den Vergleich der Modelle kann die Entscheidung robuster bewertet werden.

#### NN-orientierte Modelle

- ConvNeXt und EfficientNetV2 analysieren lokale Bildstrukturen wie Form, Oberfläche, Kanten und Texturen.

#### Transformer-orientierte Modelle

- SwinV2, DaViT und MaxViT erfassen zusätzlich größere Bildzusammenhänge und globale Muster.

#### Vortrainierte Repräsentationsmodelle

- DINOv2 und CLIP liefern robuste Bildmerkmale, die auch bei kleinen oder schwierigen Datensätzen hilfreich sein können.


Durch die Kombination dieser Modelle entsteht ein Ensemble, das nicht nur eine Einzelentscheidung liefert, sondern auch zeigt, wie einig oder uneinig die Modelle bei der Bewertung eines Kandidaten sind.

Video mit Erläuterungen zu den Verfahren: [https://www.waldhor.com/astronomie/mikrometeoriten/Die\\_Evolution\\_der\\_Backbones.mp4](https://www.waldhor.com/astronomie/mikrometeoriten/Die_Evolution_der_Backbones.mp4)

# CRISP-DM Modell: Modelling

## Beispiel: CNN – Convolutional Neural Networks

Spezielle Form eines neuronalen Netzes, das aus mehreren aufeinanderfolgenden Filtern (Feature maps) - und Verdichtungsschichten besteht, um Merkmale in Bildern oder anderen Daten automatisch zu erkennen.



RGB-Kanäle Größe 141 x 141 Pixel

| Input                                                                   | Kernel                                                | Output                                                          |
|-------------------------------------------------------------------------|-------------------------------------------------------|-----------------------------------------------------------------|
| <div><div>1321</div><div>1331</div><div>2113</div><div>3233</div></div> | <div><div>123</div><div>010</div><div>212</div></div> | <div><div>23</div><div>22</div><div>31</div><div>26</div></div> |

Filter (Feature Maps)

| Input                                                                                                               | Kernel                                                | Output                                                                                                                                                                                                                   |
|---------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <div><div>0000000</div><div>013210</div><div>013310</div><div>021130</div><div>032330</div><div>0000000</div></div> | <div><div>123</div><div>010</div><div>212</div></div> | <div><div>8</div><div>14</div><div>13</div><div>8</div><div>16</div><div>23</div><div>22</div><div>10</div><div>20</div><div>31</div><div>26</div><div>17</div><div>10</div><div>9</div><div>15</div><div>10</div></div> |

Padding


| Input                                                                                                                                    | Kernel                                                | Output                                                                                                                           |
|------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------|
| <div><div>1321221</div><div>1331212</div><div>211313</div><div>3233231</div><div>2312221</div><div>1122332</div><div>3231322</div></div> | <div><div>123</div><div>010</div><div>212</div></div> | <div><div>21</div><div>26</div><div>16</div><div>26</div><div>21</div><div>26</div><div>23</div><div>21</div><div>27</div></div> |

Dilatation

| Input                                                                                       | Kernel                                                | Expanded Output                                                 | Output                                                          |
|---------------------------------------------------------------------------------------------|-------------------------------------------------------|-----------------------------------------------------------------|-----------------------------------------------------------------|
| <div><div>13212</div><div>13312</div><div>21131</div><div>32332</div><div>23122</div></div> | <div><div>123</div><div>010</div><div>212</div></div> | <div><div>23</div><div>18</div><div>18</div><div>21</div></div> | <div><div>23</div><div>18</div><div>18</div><div>21</div></div> |

Strides

| Max Pooling                                                                     |                                                                 |
|---------------------------------------------------------------------------------|-----------------------------------------------------------------|
| Input                                                                           | Output                                                          |
| <div><div>218812</div><div>121997</div><div>81043</div><div>1812910</div></div> | <div><div>21</div><div>12</div><div>18</div><div>10</div></div> |
| Average Pooling                                                                 |                                                                 |
| Input                                                                           | Output                                                          |
| <div><div>218812</div><div>121997</div><div>81043</div><div>1812910</div></div> | <div><div>15</div><div>9</div><div>12</div><div>7</div></div>   |



CRISP-DM Modell: Modelling

Training

| Modell         | Checkpoint-Modell      | Val-Accuracy mit Blurring | Val-Accuracy mit Hintergrundentfernung |
|----------------|------------------------|---------------------------|----------------------------------------|
| MaxViT         | best_maxvit_model.pt   | 0.9705                    | 0.9475                                 |
| DINOv2         | best_dinov2_model.pt   | 0.9649                    | 0.9450                                 |
| CLIP           | best_clip_model.pt     | 0.9742                    | 0.9450                                 |
| DaViT          | best_davit_model.pt    | 0.9742                    | 0.9650                                 |
| EfficientNetV2 | best_effnet_model.pt   | 0.9742                    | 0.9550                                 |
| ConvNeXt       | best_convnext_model.pt | 0.9742                    | 0.9500                                 |
| SwinV2         | best_swinv2_model.pt   | 0.9668                    | 0.9500                                 |

CRISP-DM Modell: Modelling

PHASE 4: MODELING

Ansatz II: Die White Box – Das Expertensystem



**Technologie:**  
CLIPS-Umgebung.



**Fundament:**  
28 dedizierte Wenn-Dann-Regeln,  
extrahiert aus  
Experteninterviews.



**Vorteile:**  
Volle Erklärbarkeit der  
Entscheidung und die Fähigkeit,  
spezifische MM-Typen (z.B. B0,  
V-Type) zu benennen.



CRISP-DM Modell: Modelling


# KI-Paradigmen im Vergleich

## Maschinelles Lernen vs. Klassische KI

|               | Maschinelles Lernen (ML)                                        | Klassisches Expertensystem (KKI)                                 |
|---------------|-----------------------------------------------------------------|------------------------------------------------------------------|
| Wissensbasis  | Große Datenmengen (Bilder, Pixel, Trainingssets).               | Formalisiertes menschliches Expertenwissen (Regeln & Fakten).    |
| Lernprozess   | Automatisierte Mustererkennung durch mathematische Optimierung. | Manuelle Erstellung durch Experteninterviews (z.B. Thilo Hasse). |
| Erklärbarkeit | "Black Box" – Verborgene Entscheidungsfindung.                  | Transparent – Jeder Schritt folgt nachvollziehbarer Logik.       |
| Architektur   | Konnektionistisch (Neuronale Netze, CNNs).                      | Symbolisch (Inferenzmaschine, CLIPS).                            |


# CRISP-DM Modell: Modelling

## Die Anatomie eines Expertensystems



# CRISP-DM Modell: Modelling


## Das MM-Expertensystem im Profil



<https://www.waldhor.com/astronomie/mikrometeoriten/>


NotebookLM

CRISP-DM Modell: Modelling



# CRISP-DM Modell: Evaluation

## Beispiel 1: Die Ausschlusslogik in Aktion



Sh. zur Klassifikation von Rost Anmerkungen im Anhang

**Regelname:** Kein Mikrometeorit (NMM)

**Logik:** WENN das Objekt rostig ist, DANN handelt es sich um keinen Mikrometeoriten.


`(mm_rusty yes) => (classification NMM)`

### Erklärung:

Mikrometeoriten sind nicht rostig. Sie bestehen aus Materialien, die bei der ablativen Erhitzung im Atmosphärenflug völlig andere, verschmolzene Oberflächen bilden.

# CRISP-DM Modell: Modelling

## Beispiel 2: Die Detailanalyse in Aktion



**Regelname: BO-Typ (Barred Olivine)**

**Logik:** WENN auf der Oberfläche parallele, teils gebogene Linien zu erkennen sind, DANN ist dies ein starkes Indiz für einen BO-Typ.

`(surface_parallel_lines yes) =>  
(classification BO_Type)`

**Erklärung:** Diese spezifische Wachstumsstruktur von feinen Olivin-Dendriten kommt in dieser Form fast ausschließlich bei durch Atmosphäreneintritt aufgeschmolzenen Mikrometeoriten vor.

CRISP-DM Modell: Modelling

# Der entscheidende Vorteil: Erklärbarkeit

Warum Transparenz in der Wissenschaft unerlässlich ist

## Machine Learning ("Black Box")

Input: Bilddaten

Automatische Klassifikation (ML)

ML-Klassifikation: Mikrometeorit (MM)-Kandidat.

Schwellenwert: 76% - Durchschnittliche P(IM) des Ensembles: 54.3%

Mikrometeorit (IM)

Eigene Bewertung (Schwellenwert 76%): Durchschnittliche P(IM) = 54.3%

**Erklärung**

7 von 7 Modellen (ConvNaltt, SaliV2, ERNetV2, DeViT, MavViT, DiNov2, CLIP) bewerten dieses Bild mit einer Wahrscheinlichkeit P(IM) von 70% oder mehr für einen Mikrometeoriten. SaliV2, ERNetV2, DeViT, MavViT, DiNov2, CLIP sind sehr sicher (P(IM) > 8.5). Der Durchschnitt des Ensembles liegt bei 94.3%, den eingestellten Schwellenwert bei 76%.

**Konfidenz:** Hoch - die Modelle stimmen weitgehend überein (StdDev 0.08) und der Durchschnitt liegt deutlich über dem Schwellenwert.

**Problem:** Das Modell liefert eine Wahrscheinlichkeit, aber keine Begründung. Im Fehlerfall bleibt die Ursache verborgen.

## Expertensystem ("White Box")

Input: Morphologische Parameter

Output: Klassifikation: Mikrometeorit (BO-Typ)

Begründungskette:

Objekt ist nicht rostig → Keine unnatürlichen Farben → Oberfläche zeigt parallele, gebogene Linien.

**Fazit:** Das System liefert nicht nur ein Ergebnis, es argumentiert präzise wie ein menschlicher Experte.



CRISP-DM Modell: Evaluation

# Performance-Vergleich: Das Urteil

## Gesamtgenauigkeit (Testdatensatz)



## Identifikation von terrestrischen Imitatoren (NMM)



Während das Machine-Learning-Modell (aufgrund ungleicher Trainingsdaten) stark dazu tendiert, terrestrische Partikel als kosmischen Staub zu deklarieren, filtert das Expertensystem durch seine strenge, regelbasierte Ausschlusslogik beide Klassen gleichbleibend präzise.

CRISP-DM Modell: Evaluation

Trainingsergebnisse

Konfusionsmatrix

|              |                 | Vorhergesagte Klasse                                                                                                   |                                                                                                                      | Zeilensumme                  |
|--------------|-----------------|------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|------------------------------|
|              |                 | positiv (MM)                                                                                                           | negativ (NonMM)                                                                                                      |                              |
| Wahre Klasse | positiv (MM)    | <b>TP: 1755</b><br>Anteil gesamt: 65.78%<br>Anteil Zeile: 96.27%<br>Anteil Spalte: 98.43%<br>Erwartet (unabh.): 1218.3 | <b>FN: 68</b><br>Anteil gesamt: 2.55%<br>Anteil Zeile: 3.73%<br>Anteil Spalte: 7.68%<br>Erwartet (unabh.): 604.7     | <b>1823</b><br><b>68.33%</b> |
|              | negativ (NonMM) | <b>FP: 28</b><br>Anteil gesamt: 1.05%<br>Anteil Zeile: 3.31%<br>Anteil Spalte: 1.57%<br>Erwartet (unabh.): 564.7       | <b>TN: 817</b><br>Anteil gesamt: 30.62%<br>Anteil Zeile: 96.69%<br>Anteil Spalte: 92.32%<br>Erwartet (unabh.): 280.3 | <b>845</b><br><b>31.67%</b>  |
| Spaltensumme |                 | <b>1783</b><br><b>66.83%</b>                                                                                           | <b>885</b><br><b>33.17%</b>                                                                                          | <b>2668</b><br><b>Gesamt</b> |

| Kennzahl                    | Formel                            | Wert   | Erläuterung                                          |
|-----------------------------|-----------------------------------|--------|------------------------------------------------------|
| Accuracy                    | $(TP + TN) / N$                   | 0.9640 | Anteil korrekter Vorhersagen insgesamt.              |
| Precision / PPV             | $TP / (TP + FP)$                  | 0.9843 | Wenn als MM vorhergesagt: wie oft wirklich MM.       |
| Recall / TPR / Sensitivität | $TP / (TP + FN)$                  | 0.9627 | Wenn wirklich MM: wie oft als MM erkannt.            |
| Spezifität / TNR            | $TN / (TN + FP)$                  | 0.9669 | Wenn wirklich NonMM: wie oft als NonMM erkannt.      |
| FPR                         | $FP / (FP + TN)$                  | 0.0331 | Falsch-Positiv-Rate = 1 - Spezifität.                |
| FNR                         | $FN / (FN + TP)$                  | 0.0373 | Falsch-Negativ-Rate = 1 - Recall.                    |
| NPV                         | $TN / (TN + FN)$                  | 0.9232 | Wenn als NonMM vorhergesagt: wie oft wirklich NonMM. |
| F1-Score                    | $2 \cdot Pr \cdot Re / (Pr + Re)$ | 0.9734 | Harmonisches Mittel von Precision und Recall.        |

CRISP-DM Modell: Evaluation

Testergebnisse

Konfusionsmatrix

|              |                 | Vorhergesagte Klasse                                                                                          |                                                                                                             | Zeilensumme   |
|--------------|-----------------|---------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------|---------------|
|              |                 | positiv (MM)                                                                                                  | negativ (NonMM)                                                                                             |               |
| Wahre Klasse | positiv (MM)    | TP: 326<br>Anteil gesamt: 75.81%<br>Anteil Zeile: 82.12%<br>Anteil Spalte: 95.32%<br>Erwartet (unabh.): 315.8 | FN: 71<br>Anteil gesamt: 16.51%<br>Anteil Zeile: 17.88%<br>Anteil Spalte: 80.68%<br>Erwartet (unabh.): 81.2 | 397<br>92.33% |
|              | negativ (NonMM) | FP: 16<br>Anteil gesamt: 3.72%<br>Anteil Zeile: 48.48%<br>Anteil Spalte: 4.68%<br>Erwartet (unabh.): 26.2     | TN: 17<br>Anteil gesamt: 3.95%<br>Anteil Zeile: 51.52%<br>Anteil Spalte: 19.32%<br>Erwartet (unabh.): 6.8   | 33<br>7.67%   |
| Spaltensumme |                 | 342<br>79.53%                                                                                                 | 88<br>20.47%                                                                                                | 430<br>Gesamt |


Gütemaße

| Kennzahl                    | Formel                            | Wert   | Erläuterung                                          |
|-----------------------------|-----------------------------------|--------|------------------------------------------------------|
| Accuracy                    | $(TP + TN) / N$                   | 0.7977 | Anteil korrekter Vorhersagen insgesamt.              |
| Precision / PPV             | $TP / (TP + FP)$                  | 0.9532 | Wenn als MM vorhergesagt: wie oft wirklich MM.       |
| Recall / TPR / Sensitivität | $TP / (TP + FN)$                  | 0.8212 | Wenn wirklich MM: wie oft als MM erkannt.            |
| Spezifität / TNR            | $TN / (TN + FP)$                  | 0.5152 | Wenn wirklich NonMM: wie oft als NonMM erkannt.      |
| FPR                         | $FP / (FP + TN)$                  | 0.4848 | Falsch-Positiv-Rate = 1 - Spezifität.                |
| FNR                         | $FN / (FN + TP)$                  | 0.1788 | Falsch-Negativ-Rate = 1 - Recall.                    |
| NPV                         | $TN / (TN + FN)$                  | 0.1932 | Wenn als NonMM vorhergesagt: wie oft wirklich NonMM. |
| F1-Score                    | $2 \cdot Pr \cdot Re / (Pr + Re)$ | 0.8823 | Harmonisches Mittel von Precision und Recall.        |

CRISP-DM Modell: Evaluation

PHASE 5: EVALUATION

# Die Symbiose: Der hybride Workflow



# CRISP-DM Modell: Deployment


## PHASE 6: DEPLOYMENT

### Der finale Orbit: Rollout in die Community



**Containerisierung:** Das finale Modell wird als leichtgewichtiger Docker-Container verpackt, sofort einsatzbereit.

**Web-Plattform:** Upload-Seite für Hobby-Sucher zur sekundenschnellen Ersteinschätzung.



**Der nächste Horizont:** Automatische Segmentierung. Die KI analysiert komplette Petrischalen-Übersichten in Echtzeit und markiert Kandidaten direkt unter dem Stereomikroskop.

# CRISP-DM Modell: Deployment

- Als Docker Image
- <https://www.waldhor.com/astronomie/mikrometeoriten/>

Das Expertensystem läuft in der Webseite ohne Service und ist direkt nutzbar.

### ML basiertes Klassifikationssystem und Expertensystem für Mikrometeoriten v1.7

Als PDF exportieren

Theme

DE

Sprache

Bedienung

Architektur

ML

Spec

Mikrometeorit

Demo

Prompt

Impressum

Bild des Objekts hochladen / Upload object image

Datei auswählen

THMM57...6).jpg.png

Das Bild bleibt lokal im Browser und wird nicht an einen Server übertragen.



Schwellenwert für MM (in %):  (Standard: 50%, Bild gilt als MM, wenn die durchschnittliche P(MM) des Ensembles  $\geq$  Schwellenwert ist.)

Modellgruppe: Background-Removal trainiert (rembg, weiss)

Vorverarbeitung: Background-Removal (rembg)

Service verbunden (v1.3.0)

ML-MM-Klassifikation starten

ML-Klassifikation erfolgreich durchgeführt.

Automatische Klassifikation (ML)

ML-Klassifikation: Mikrometeorit (MM)-Kandidat.

Schwellenwert: 70% – Durchschnittliche P(MM) des Ensembles: 90.0%.

Mikrometeorit (MM)

Eigene Bewertung (Schwellenwert 70%): Durchschnittliche P(MM) = 90.0%

Erklärung

7 von 7 Modellen (ConvNeXt, SwinV2, EffNetV2, DaViT, MaxViT, DiNOv2, CLIP) bewerten dieses Bild mit einer Wahrscheinlichkeit P(MM) von 70% oder mehr für einen Mikrometeoriten. SwinV2, DaViT, MaxViT, DiNOv2 sind sehr sicher (P(MM)  $\geq$  0.9). Der Durchschnitt des Ensembles liegt bei 90.0%, dein eingestellter Schwellenwert bei 70%.

**Konfidenz:** Hoch – die Modelle stimmen weitgehend überein (StdDev 0.01) und der Durchschnitt liegt deutlich über dem Schwellenwert.

```
C:\WINDOWS\system32\cmd. X + v
2026-06-18 07:28:18 [INFO] ] mmservice: =====
2026-06-18 07:28:18 [INFO] ] mmservice: Service-Start Log-Verzeichnis: d:\Astronomie\Mikrometeoriten\MM_Docker\logs
2026-06-18 07:28:18 [INFO] ] mmservice: =====
2026-06-18 07:28:28 [INFO] ] mmservice: Service-Config geladen aus d:\Astronomie\Mikrometeoriten\MM_Docker\model_config.j
son
2026-06-18 07:28:28 [INFO] ] mmservice: Verfügbare Modellgruppen: ['normal', 'blur', 'rembg']
2026-06-18 07:28:28 [INFO] ] mmservice: Default-Gruppe: rembg
2026-06-18 07:28:28 [INFO] ] mmservice: Default-Vorverarbeitung: rembg
2026-06-18 07:28:28 [INFO] ] mmservice: Lade YOLO aus d:\Astronomie\Mikrometeoriten\MM_Docker\./runs/detect/train3/weight
s/best.pt
[INIT] Verwende Device: cuda
2026-06-18 07:28:28 [INFO] ] mmservice: Lade Modellgruppe 'normal' aus d:\Astronomie\Mikrometeoriten\MM_Docker\./checkpoi
nts
Lade Modellgruppe 'normal' aus d:\Astronomie\Mikrometeoriten\MM_Docker\./checkpoints
convnext: geladen aus best_convnext_model.pt
swinv2: geladen aus best_swinv2_model.pt
efficientnetv2: geladen aus best_effnet_model.pt
davit: geladen aus best_davit_model.pt
maxvit: geladen aus best_maxvit_model.pt
dinov2: geladen aus best_dinov2_model.pt
clip: geladen aus best_clip_model.pt
2026-06-18 07:28:33 [INFO] ] mmservice: Lade Modellgruppe 'blur' aus d:\Astronomie\Mikrometeoriten\MM_Docker\./checkpoint
s_blur
Lade Modellgruppe 'blur' aus d:\Astronomie\Mikrometeoriten\MM_Docker\./checkpoints_blur
convnext: geladen aus best_convnext_model.pt
swinv2: geladen aus best_swinv2_model.pt
efficientnetv2: geladen aus best_effnet_model.pt
davit: geladen aus best_davit_model.pt
maxvit: geladen aus best_maxvit_model.pt
dinov2: geladen aus best_dinov2_model.pt
clip: geladen aus best_clip_model.pt
2026-06-18 07:28:37 [INFO] ] mmservice: Lade Modellgruppe 'rembg' aus d:\Astronomie\Mikrometeoriten\MM_Docker\./checkpoi
ts_nobg
Lade Modellgruppe 'rembg' aus d:\Astronomie\Mikrometeoriten\MM_Docker\./checkpoints_nobg
convnext: geladen aus best_convnext_model.pt
swinv2: geladen aus best_swinv2_model.pt
efficientnetv2: geladen aus best_effnet_model.pt
davit: geladen aus best_davit_model.pt
maxvit: geladen aus best_maxvit_model.pt
dinov2: geladen aus best_dinov2_model.pt
clip: geladen aus best_clip_model.pt
2026-06-18 07:28:42 [INFO] ] mmservice: Service bereit. Geladene Gruppen: ['normal', 'blur', 'rembg']
INFO: Started server process [13612]
INFO: Waiting for application startup.
INFO: Application startup complete.
INFO: Uvicorn running on http://0.0.0.0:8000 (Press CTRL+C to quit)
INFO: 127.0.0.1:59462 - "GET /service_info HTTP/1.1" 200 OK

0: 640x544 1 mikrometeorit_kandidat, 26.7ms
Speed: 27.1ms preprocess, 26.7ms inference, 11.6ms postprocess per image at shape (1, 3, 640, 544)
DEBUG: Gefundene Boxen: 1
DEBUG: Klasse 0.0 mit Konfidenz 0.78
DEBUG: YOLO hat mikrometeorit_kandidat erkannt: 0.781878886070251
DEBUG: Mask-Blur erzeugt (Methode=yolo, ksize=31)
2026-06-18 07:29:09 [INFO] ] mmservice: rembg-Session geladen (Modell: u2net)
DEBUG: Background-Removal erzeugt
INFO: 127.0.0.1:56823 - "POST /mmclassify HTTP/1.1" 200 OK
```

21.06.2026

Machine Learning für Amateurastronomen - Kleinplanetentagung 2026 - Prof. Dr. Klemens Waldhör

56

# 03

## Astronomische Softwareentwicklung mit LLMs

10 Regeln für die KI unterstützte Softwareentwicklung

# Erfolgreiche Prompts schreiben


## Das Präzisionsproblem: KI und astronomische Koordinaten

### Der naive Ansatz

Zeige mir den Stern.



### Die technische Spezifikation



#### RA/DEC (J2000)

RA: 05h 35m 17.3s

DEC: -05° 23' 28"

#### UTC Zeitzone

ZEIT: 2024-10-27 02:00:00

OFFSET: +00:00

#### Beobachtungsort Breitengrad

LAT: +48.8566° N

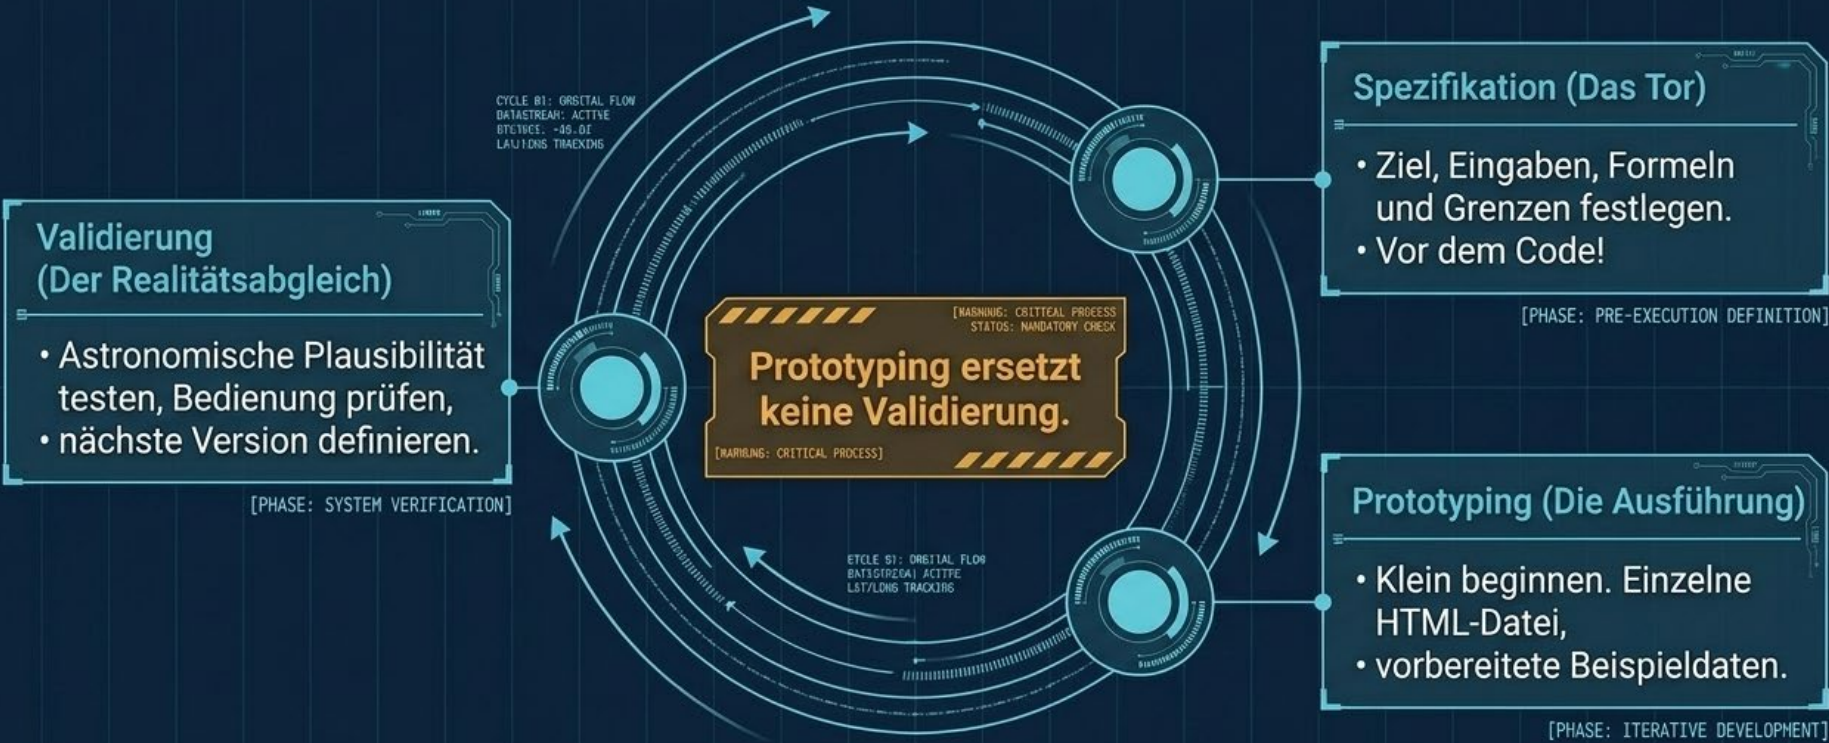
LONG: +2.3522° E

Ein LLM kennt astronomische Begriffe, überprüft aber nicht automatisch, ob Epoche, Zeitzone oder Näherungsformeln zur Aufgabe passen.

Die Regel: Prompts in der Astronomie sind keine lockeren Chats – sie sind **exakte technische Spezifikationen**.

Erfolgreiche Prompts schreiben

Der Workflow: Prompting als interaktiver Kreislauf



Der Paradigmenwechsel: Wir bitten das LLM nicht, ein Programm zu schreiben.  
Wir zwingen es in einen **geführten Entwicklungszyklus**.

[SYSTEM NOTE: GUIDED DEVELOP CYCLE ENGAGED - PROMPT PROTOCOL ACTIVATED]

# Erfolgreiche Prompts schreiben

## Die Pyramide der Präzision: 10 Regeln für astronomische Prompts



Jede Ebene stützt die nächste. Ohne ein starkes **fachliches Fundament** kollabiert selbst der am besten geschriebene Code unter astronomischen Realbedingungen.

Erfolgreiche Prompts schreiben

Fundament I: Kontext & Zielvorgabe

Regel 1: Korrekte astronomische Terminologie verwenden.

Terminology Glossary

- ☐ Rektaszension/RA
- ☐ Deklination/DEC
- ☐ Höhe/Altitude
- ☐ Azimut
- ☐ UTC
- ☐ MESZ
- ☐ J2000

Keine mehrdeutigen Kurzformen.  
Exakte Definitionen fordern.

Regel 2: Ziel und Anwendungsfall konkretisieren.

User Persona Profile



Falsch:

Erstelle ein Astro-Tool.

Richtig:

Ein Werkzeug für Amateurastronomen auf dem Feld, um die Sichtbarkeit vor der Beobachtungsnacht zu bewerten.

## Fundament II: Strukturierte Daten und Parameter

### Regel 3: Eingaben, Einheiten und Formate festlegen.

Ein LLM muss wissen, ob RA in Dezimalgrad oder Stunden/Minuten/Sekunden vorliegt.

Beispiel: CSV-Format exakt vorgeben.

#### Eingaben-Parser

Breitengrad (Dezimal)

RA (Stunden, Minuten, Sekunden)

Zeit (Lokal oder UTC?)

### Regel 4: Ausgaben und Bewertungskriterien definieren.

Begriffe wie 'gut beobachtbar' sind nutzlos ohne harte Metriken.

#### Ausgabe-Metriken



Grün = >25° Höhe

# Erfolgreiche Prompts schreiben

## Fundament III: Kontrolle über Ausführung und Umfang



### Regel 5: Spezifikation vor Code erzwingen.

Lassen Sie das LLM zuerst Annahmen, Grenzen und den Bedienablauf ausgeben. Erst bei Freigabe darf programmiert werden.

### Regel 6: Umfang strikt begrenzen.

Live-Demo-Modus: Alles muss in einer einzigen HTML-Datei laufen. Keine externen Bibliotheken, keine komplexen Server-APIs.

Erfolgreiche Prompts schreiben

# Fundament IV: Transparenz und Testbarkeit

## Regel 7: Erklärungen zu Formeln und Näherungen verlangen.

Die Anwendung muss offenlegen, welche vereinfachten Formeln genutzt wurden, um falsche Exaktheit zu vermeiden.

### ALT/AZ COMPUTATION FORMULA


```
// Calculate Altitude
alt_rad = asin(sin(dec_rad) * sin(lat_rad) +
               cos(dec_rad) * cos(lat_rad) * cos(LHA_rad));

// Simplified Refraction (Approx.)
refraction_corr = 0.0002967 / tan(alt_rad + 0.00312536 /
                                  (alt_rad + 0.0890118));
APPROXIMATION WARNING: Simplified Model
alt_deg_final = (alt_rad + refraction_corr) * 180.0 / PI;
```

## Regel 8: Testfälle und Plausibilität einbauen.

Fordern Sie bekannte Referenzwerte direkt im Prompt ein, um das Ergebnis sofort mit Stellarium oder ASTAP gegenprüfen zu können.

### REFERENZ-KOORDINATEN



Erfolgreiche Prompts schreiben

# Fundament V: Kontinuität und LLM-Gedächtnis

**Regel 9:** Ergebnisse und Versionen dokumentieren.

Lassen Sie Änderungen nachvollziehbar kommentieren. Aus Demos werden schnell Vereinsprojekte.

**Regel 10:** Das begrenzte Gedächtnis berücksichtigen.

LLMs vergessen Vorgaben in langen Chats. Wiederholen Sie zentrale Regeln und arbeiten Sie mit klaren Änderungsaufträgen.



# 04 Zusammenfassung

# Verbesserung Mikrometeoritenerkennung

## Bilder

- Ausgewogenes Verhältnis Mikrometeoriten zu Nichtmikrometeoriten
- Eingangsqualitätsprüfung der Bilder
- Manuelle Kuratierung der Bilder
- Training on the Fly
- ...

## Zukunftsmusik

- Regeln direkt in die ML-Klassifikation integrieren
- Eigene Schicht?

# Verbesserung Mikrometeoritenerkennung

## Die hybride Zukunft der Klassifizierung

Symbiose aus Computer Vision und klassischer Logik



### 1. Rohdaten


Unsortiertes hochauflösendes Bildmaterial vom Objektträger.



### 2. ML-Vorfilter

CNNs übernehmen Bildsegmentierung und extrahieren visuelle Parameter (Form, Farbe, Kanten).

Übergabe der Merkmale



### 3. Logic Verification

Das Expertensystem wendet die 28 Regelknoten an, verifiziert die Konsistenz und generiert eine menschenlesbare Begründung.

Diese hybride Architektur ermöglicht **massive Zeitersparnisse bei der Suche** und **entlastet menschliche Experten** von der **zeitraubenden Vorauswahl**.

## Übertragbarkeit auf industrielle Partikelanalyse

Die Klassifikation kleinster Partikel ist ein zentrales Thema in zahlreichen Industriebereichen:

- Metallurgie (Schlacke- und Partikelanalyse)
- Additive Fertigung (Pulverqualität)
- Halbleiterfertigung (Kontaminationsanalyse)
- Pharmaindustrie (Partikelverunreinigungen)
- Umwelttechnik (Feinstaubcharakterisierung)

Ein trainiertes Expertensystem für Mikrometeoriten ist methodisch nahezu identisch mit Systemen zur automatisierten Qualitätskontrolle mikroskopischer Partikel. Es liefert damit einen Proof-of-Concept für industrielle Anwendungen.

Im Kontext zukünftiger Missionen (z. B. Sample-Return-Missionen oder Mars-Regolith-Analysen) sind autonome Klassifikationssysteme essenziell. Ein solches Expertensystem ist konzeptionell vergleichbar mit Systemen, die bei Missionen wie:

Hayabusa2

OSIRIS-REx

zur Materialanalyse eingesetzt werden (wenn auch dort technisch deutlich komplexer).

## Programmierung von Astronomiesoftware

LLMs können programmieren – aber ohne tiefes Verständnis - wobei man selbst oft ins Zweifeln kommt, ob sie kein Verständnis haben. LLMs revolutionieren die Softwareentwicklung – aber nicht automatisch die Qualität.

### Prompt-Engineering als Schlüsselfaktor

- Iterative Prompts
- Prototypen-Prompts
- Prompt-Plan – Prozess
- Dokumentation der Prompts
- Wiederholung der Prompts in unterschiedlichen LLM-Systemen

Nur wer die Anwendungsdomäne versteht, kann Qualität sichern. Qualitätssicherung bleibt der Schlüssel. Softwareentwicklung wird zum Co-Creation – Pair Programming.

- Domänen wie Astronomie sind ein guter Härte-test, da viele unterschiedliche Anwendungsfälle konstruierbar.

### Brauchen wir noch Anwendungsentwickler?

- LLMs übernehmen Handwerk, (noch) nicht das Denken,
- Neue Rollen: Prompt Engineer, Kurator, QS-Spezialist
- Mensch bleibt entscheidend für Domänenverständnis.

# 05


## Anhang

Beispielklassifikationen MM/NMM Bilder Gerhard Grau  
Rost und Mikrometeoriten

Beispielklassifikationen

Gerhard Grau, MM06.1.U21.jpg

Beispiel einer korrekten Klassifikation  
Übereinstimmung ML und  
Expertensystemurteil



ML basiertes Klassifikationssystem und  
Expertensystem für Mikrometeoriten v1.7

Automatische Klassifikation (ML)

ML-Klassifikation: Mikrometeorit (MM)-Kandidat.

Schwellenwert: 70% – Durchschnittliche P(MM) des Ensembles: 89.9%.

Mikrometeorit (MM)

Eigene Bewertung (Schwellenwert 70%): Durchschnittliche P(MM) = 89.9%

Erklärung

7 von 7 Modellen (ConvNeXt, SwinV2, EffNetV2, DaViT, MaxViT, DINOv2, CLIP) bewerten dieses Bild mit einer Wahrscheinlichkeit P(MM) von 70% oder mehr für einen Mikrometeoriten. ConvNeXt, SwinV2, DaViT, DINOv2 sind sehr sicher ( $P(MM) \geq 0.9$ ). Der Durchschnitt des Ensembles liegt bei 89.9%, dein eingestellter Schwellenwert bei 70%.

**Konfidenz:** Hoch – die Modelle stimmen weitgehend überein (StdDev 0.01) und der Durchschnitt liegt deutlich über dem Schwellenwert.

Mikrometeorit-Analyse (V4)

YOLO hat mikrometeorit\_kandidat erkannt: 0.8713153004646301

✓ Sicher (Einstimmig MM)


Ergebnis: MM (Schwellenwert 70%)

| Modell       | P(MM) |
|--------------|-------|
| ConvNeXt     | 0.902 |
| SwinV2       | 0.900 |
| EffNetV2     | 0.890 |
| DaViT        | 0.915 |
| MaxViT       | 0.889 |
| DINOv2       | 0.903 |
| CLIP         | 0.896 |
| Durchschnitt | 0.899 |


Modell-Varianz (StdDev): 0.008

Bildvarianten & Vorverarbeitung

Modellgruppe: Background-Removal trainiert (rembg, weiss) - aktive Vorverarbeitung: Background-Removal (rembg)



Beispielklassifikationen



Mikrometeorit-Befund

Auswertung vom 2026-06-22

Ergebnis

Der Partikel wird als Mikrometeorit eingestuft. Vermuteter Typ: CC (chondritisch / Cosmic Spherule). Grund: Turtleback-Oberfläche in Kombination mit den vorherigen Merkmalen spricht für einen CC-Mikrometeorit.

✓✓✓ Evidenz-Stufe: stark belegt

Literaturbasis:

Genge, M. J., Engrand, C., Gounelle, M., & Taylor, S. (2008). The classification of micrometeorites. Meteoritics & Planetary Science 43, 497-515. DOI: 10.1111/j.1945-5100.2008.tb00668.x [DOI]  
Folco, L., & Cordier, C. (2015). Micrometeorites. EMU Notes in Mineralogy 15, 253-297. DOI: 10.1180/EMU-notes.15.9 [DOI]  
Suttle, M. D., Hasse, T., & Hecht, L. (2021). Evaluating urban micrometeorites as a research resource - A large population collected from a single rooftop. Meteoritics & Planetary Science 56, 1531-1555. DOI: 10.1111/maps.13712 [DOI]

Eingeschätzte Konfidenz: 84 %

Abgleich mit ML-Klassifikation

Expertensystem und ML-Klassifikation stimmen überein (MM).

Antworten im Überblick

| Merkmal                                                            | Antwort | subj. Sicherheit |
|--------------------------------------------------------------------|---------|------------------|
| Stark aerodynamische Tropfenform (mehrere Schweife / asymmetrisch) | Nein    | 70 %             |
| Mehrere aneinanderhängende Kugeln                                  | Nein    | 70 %             |
| Saubere Oberfläche mit Kristallen                                  | Ja      | 70 %             |
| Sammlungs-Kontext: urban (Dach / Stadtboden)                       | Ja      | 70 %             |
| Farblos / grau im Auflicht                                         | Ja      | 70 %             |
| Überwiegend glasig                                                 | Nein    | 70 %             |
| Irideszenz / Ölschimmer                                            | Nein    | 70 %             |
| Mehrere Schweife / Anhängsel                                       | Nein    | 70 %             |
| Auffällig rot/orange oder blau                                     | Nein    | 70 %             |
| Vollständig durchgerostet, keine MM-Struktur erkennbar             | Nein    | 70 %             |
| Lokale Rostspuren oder Verwitterungs-Kruste                        | Nein    | 70 %             |
| Größe im typischen MM-Bereich                                      | Ja      | 70 %             |
| Turtleback-Oberfläche                                              | Ja      | 70 %             |


| Merkmal                                             | Antwort | subj. Sicherheit |
|-----------------------------------------------------|---------|------------------|
| Twins / Aggregate                                   | Nein    | 70 %             |
| Massive Verwitterung (Van-Ginneken-Stufe 3 oder 3c) | Nein    | 70 %             |

Verlauf der Fragen

- Sammlungs-Kontext: Wurde das Partikel von einem urbanen Standort gesammelt (z.B. Dach, Regenrinne, Stadtboden, Schornsteinrauch)? → Ja
- Liegt der Durchmesser der Sphäre im typischen MM-Bereich (z.B. 0,15–0,3 mm)? → Ja
- Zeigt die Sphäre einen öl- oder benzinartigen Schiller (Irideszenz)? → Nein
- Ist die Sphäre vollständig durchgerostet, ohne erkennbare sphärische Grundform und ohne sichtbaren Magnetit-Rim? → Nein
- Zeigt die Sphäre lokale Rostspuren wie gelb-braune Verwitterungs-Krusten, Ferrihydrit-Punkte um Vesikel-Öffnungen, oder einen korrodierten Metall-Bead im Inneren, während die sphärische Grundform und ggf. der Magnetit-Rim noch erkennbar sind? → Nein
- Ist die Verwitterung so massiv, dass die primäre MM-Textur (Magnetit-Rim, Olivin-Bänder, dendritische Innenstrukturen) vollständig überdeckt oder durch Pseudomorphose ersetzt ist (Stufe 3 oder 3c nach Van Ginneken et al. 2016)? → Nein
- Hat die Sphäre mehrere deutlich voneinander getrennte Schweife oder Anhängsel (NICHT zu verwechseln mit dem einzelnen aerodynamischen Schweif eines CCT)? → Nein
- Besteht der Partikel aus zwei oder mehr fest miteinander verschmolzenen Kugeln (Zwillings-Konfiguration)? → Nein
- Besteht der Partikel aus mehreren aneinanderhängenden Kugeln oder Kügelchen? → Nein
- Hat die Sphäre eine asymmetrische Tropfenform mit MEHREREN deutlichen Schweifen oder eine sehr unregelmässige aerodynamische Geometrie (im Gegensatz zu einem einzelnen, schlanken aerodynamischen Schweif wie bei CCT-Typen)? → Nein
- Hat die Sphäre überwiegend eine saubere Oberfläche mit Kristallen (ohne dicke Anhaftungen)? → Ja
- Wirkt der Partikel überwiegend glasig? → Nein
- Wirkt die Sphäre im Auflicht eher farblos/grau (nicht kräftig rot oder blau)? → Ja
- Zeigt die Sphäre auffällig rote/orange oder blaue Farbtöne? → Nein
- Hat die Oberfläche ein typisch „schildkrötenartiges“ (turtleback) Muster? → Ja

Beispielklassifikationen

Gerhard Grau, VHX\_000024 MM08.2.



Beispiel einer Fehlklassifikation  
Vermutlicher Grund dafür in den Trainingsdaten fehlen Bilder dieses Typs

ML basiertes Klassifikationssystem und Expertensystem für Mikrometeoriten v1.7

Automatische Klassifikation (ML)

ML-Klassifikation: Mikrometeorit (MM)-Kandidat.

Schwellenwert: 70% – Durchschnittliche P(MM) des Ensembles: 73.1%.

Mikrometeorit (MM)

Eigene Bewertung (Schwellenwert 70%): Durchschnittliche P(MM) = 73.1%

Erklärung

5 von 7 Modellen (SwinV2, EffNetV2, DaViT, DINOv2, CLIP) bewerten dieses Bild mit einer Wahrscheinlichkeit P(MM) von 70% oder mehr für einen Mikrometeoriten. ConvNeXt, MaxViT liegen unter diesem Schwellenwert. DaViT ist sehr sicher ( $P(MM) \geq 0.9$ ). Der Durchschnitt des Ensembles liegt bei 73.1%, dein eingestellter Schwellenwert bei 70%.

**Konfidenz:** Niedrig – der Ensemble-Durchschnitt (73.1%) liegt sehr nahe am gewählten Schwellenwert (70%). Eine kleine Änderung des Schwellenwerts könnte das Ergebnis umkehren. Manuelle Nachkontrolle empfohlen.

Mikrometeorit-Analyse (V4)

YOLO hat mikrometeorit\_kandidat erkannt: 0.8619745373725891

⚠ Mehrheitsentscheidung (MM 5/7)


Ergebnis: MM (Schwellenwert 70%)

| Modell       | P(MM) |
|--------------|-------|
| ConvNeXt     | 0.474 |
| SwinV2       | 0.899 |
| EffNetV2     | 0.849 |
| DaViT        | 0.920 |
| MaxViT       | 0.226 |
| DINOv2       | 0.855 |
| CLIP         | 0.898 |
| Durchschnitt | 0.731 |

Modell-Varianz (StdDev): 0.251

Bildvarianten & Vorverarbeitung


Modellgruppe: Background-Removal trainiert (rembg, weiss) - aktive Vorverarbeitung: Background-Removal (rembg)




Original (mit Verdict-Rahmen)

Mask-Blur (ksize=31)


Background-Removal (rembg, weiß) ← In die Modelle




Erkannte Maske: grün=Objekt / rot=Hintergrund




CONVNEXT




SWINV2




EFFNET




DAVIT



MAXVIT



DINOv2




CLIP

# Beispielklassifikationen

Gerhard Grau, VHX\_000024 MM08.2.jpg

Mit dem Expertensystem wird schnell ermittelt, dass hier kein Mikrometeorit vorliegt



### Mikrometeorit-Befund

Auswertung vom 2026-06-22

### Ergebnis

Der Partikel wird NICHT als Mikrometeorit eingestuft. Grund: Deutliche Irideszenz ist untypisch für Mikrometeoriten.

✓ **Evidenz-Stufe:** Heuristik / Erfahrungsregel

**Literaturbasis:**

- Larsen, J. (2017). In Search of Stardust: Amazing Micrometeorites and Their Terrestrial Imposters. Voyageur Press
- Larsen, J. (2019). On the Trail of Stardust: The Guide to Finding Micrometeorites. Voyageur Press

Eingeschätzte Konfidenz: 68 %

**Abgleich mit ML-Klassifikation**

Expertensystem (NMM) und ML-Klassifikation (MM) weichen voneinander ab.

**Antworten im Überblick**

| Merkmal                                      | Antwort | subj. Sicherheit |
|----------------------------------------------|---------|------------------|
| Sammlungs-Kontext: urban (Dach / Stadtboden) | Ja      | 70 %             |
| Irideszenz / Ölschimmer                      | Ja      | 70 %             |
| Größe im typischen MM-Bereich                | Ja      | 70 %             |

**Verlauf der Fragen**

- Sammlungs-Kontext: Wurde das Partikel von einem urbanen Standort gesammelt (z.B. Dach, Regenrinne, Stadtboden, Schornsteinrauch)? → Ja
- Liegt der Durchmesser der Sphäre im typischen MM-Bereich (z.B. 0,15–0,3 mm)? → Ja
- Zeigt die Sphäre einen öl- oder benzinartigen Schiller (Irideszenz)? → Ja

## Rost und Mikrometeoriten

Aus dem **Publikum** kam die Frage, warum Mikrometeoriten nicht rosten sollen. Typische Meteoriten rosten durchaus.

In den Folien wird die Regel aufgeführt, dass Rost als Kriterium für Nichtmeteoriten eingesetzt wird. Diese Darstellung ist stark vereinfacht und nur eine Heuristik. In der Realität können Mikrometeoriten rosten.

Vollständige Durchrostung ohne erhaltene Mikrometeorit-Diagnostik ist ein starkes Indiz für terrestrische Eisen-Industriepartikel wie Schweißperlen, Stahl-Strahlmittel oder Bremsstaub. Diese bestehen aus reinem Eisen oder Stahl ohne schützende Silikat- oder Magnetit-Phasen, sodass sie unter atmosphärischer Feuchtigkeit gleichmäßig durchoxidieren und ihre sphärische Form sowie alle inneren Strukturen verlieren. Echte Mikrometeoriten besitzen dagegen entweder eine Magnetit-Wüstit-Außenhülle (I-Typ) oder eine silikatische Olivin-/Glas-Matrix (S-/G-Typ), die als Korrosionsschutz wirken — sie können zwar lokal verwittern (Ferrihydrit-Punkte, gelb-bräunliche Krusten), behalten aber die diagnostischen Innenstrukturen.

Allerdings: Rost allein ist kein eindeutiges Ausschlusskriterium. Antarktische Mikrometeoriten (terrestrische Alter bis 2,3 Millionen Jahre) zeigen routinemäßig Verwitterungsstufen 1–3 der Van-Ginneken-Skala, Tiefsee-MMs sind durch Salzwasser stark alteriert, und urbane MMs in säurebelasteten Umgebungen (Beispiel: Budel-Sammlung) entwickeln ähnliche Krusten in wenigen Jahren. Bei I-Typ-MMs sind Ferrihydrit-Spots um den FeNi-Bead sogar diagnostisch. Das Expertensystem differenziert deshalb in seiner aktuellsten Variante fünf Fälle.

Mehr zu den Quellen unter: [https://www.waldhor.com/astronomie/mikrometeoriten/help\\_mikrometeoriten.html](https://www.waldhor.com/astronomie/mikrometeoriten/help_mikrometeoriten.html)

## Rost und Mikrometeoriten

- 1. Sammlungs-Kontext-Vorfilter:** Bei polaren, Tiefsee- oder fossilen Sammlungen wird die strenge Rost-Frage automatisch übersprungen, da Verwitterung in diesen Kontexten erwartungsgemäß ist und kein NMM-Hinweis darstellt. Nur urbane oder unklare Sammlungen durchlaufen die volle Rost-Prüfung.
- 2. Vollständige Durchrostung:** Frage: *"Ist die Sphäre vollständig durchgerostet, ohne erkennbare sphärische Grundform und ohne sichtbaren Magnetit-Rim?"* — Ja → Klassifikation NMM, Begründung: terrestrische Eisen-Industrie. Nein → weiter zur nächsten Frage.
- 3. Lokale Rostspuren:** Frage: *"Zeigt die Sphäre lokale Rostspuren wie gelb-braune Krusten, Ferrihydrit-Punkte oder einen korrodierten Metall-Bead, während die sphärische Grundform und ggf. der Magnetit-Rim noch erkennbar sind?"* — Diese Frage ist die Differenzierungsstelle. Ja → I-Typ-Prüfung. Nein → Intensitäts-Prüfung.
- 4. I-Typ-Diagnostik:** Frage: *"Sind die Rostspuren punktuell um einen Metall-Kern konzentriert (Ferrihydrit-Spots um FeNi-Bead, oder Magnetit-Wüstit-Körper mit korrodiertem Metall-Einschluss)"* — statt einer gleichmäßigen Kruste?" — Ja → Konklusion positive I-Typ-Klassifikation (Quelle: Genge et al. 2017, GCA 218). Nein → Verwitterungs-Intensität.
- 5. Verwitterungs-Intensität:** Frage: *"Ist die Verwitterung so massiv, dass die primäre MM-Textur vollständig überdeckt oder durch Pseudomorphose ersetzt ist (Stufe 3 oder 3c nach Van Ginneken et al. 2016)?"* — Diese Frage modifiziert die Konfidenz: Stufen 0–2 sind MM-kompatibel, Stufe 3–3c im urbanen Kontext eine Warnung, im fossilen/antarktischen Kontext normal.

Vielen Dank für Eure Aufmerksamkeit!

waldhoer@waldhor.com