


PV4C

Satellitengestützte Solar- Echtzeit-Vorhersage für Energiegemeinschaften:

Ein KI-gestütztes Framework zur PV-Erkennung
und Produktionsprognose



EnInnov2026

19. Symposium Energieinnovation | 11.02.-13.02.2026

Lukas Prenner
Doris Oberleiter

Irene Schicker Matthias Schlögl
Nikta Madjdi Matthias Göbel
Pascal Gfäller Petrina Papazek
Jasmina Hadzimustafic

Roland Perko
Sead Mustafic



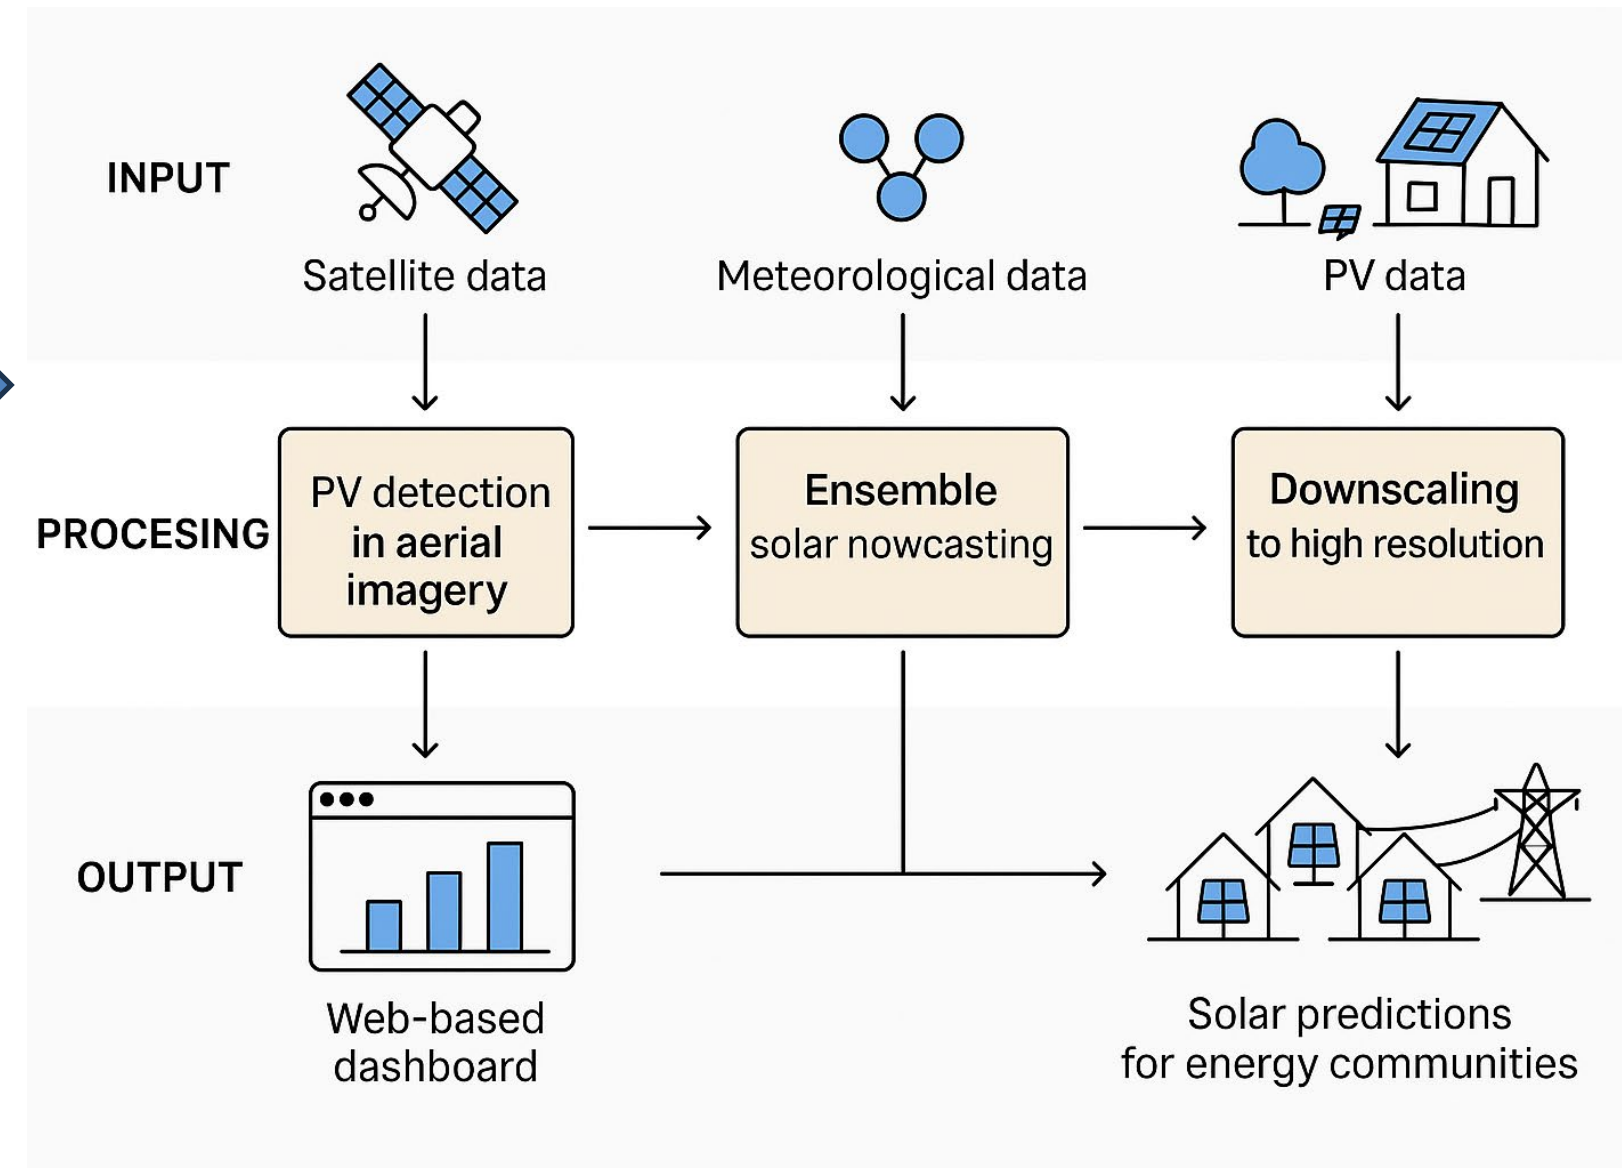

Dieses Projekt wird aus Mitteln
der FFG gefördert. www.ffg.at

Motivation

Warum PV-Prognosen für Energiegemeinschaften?

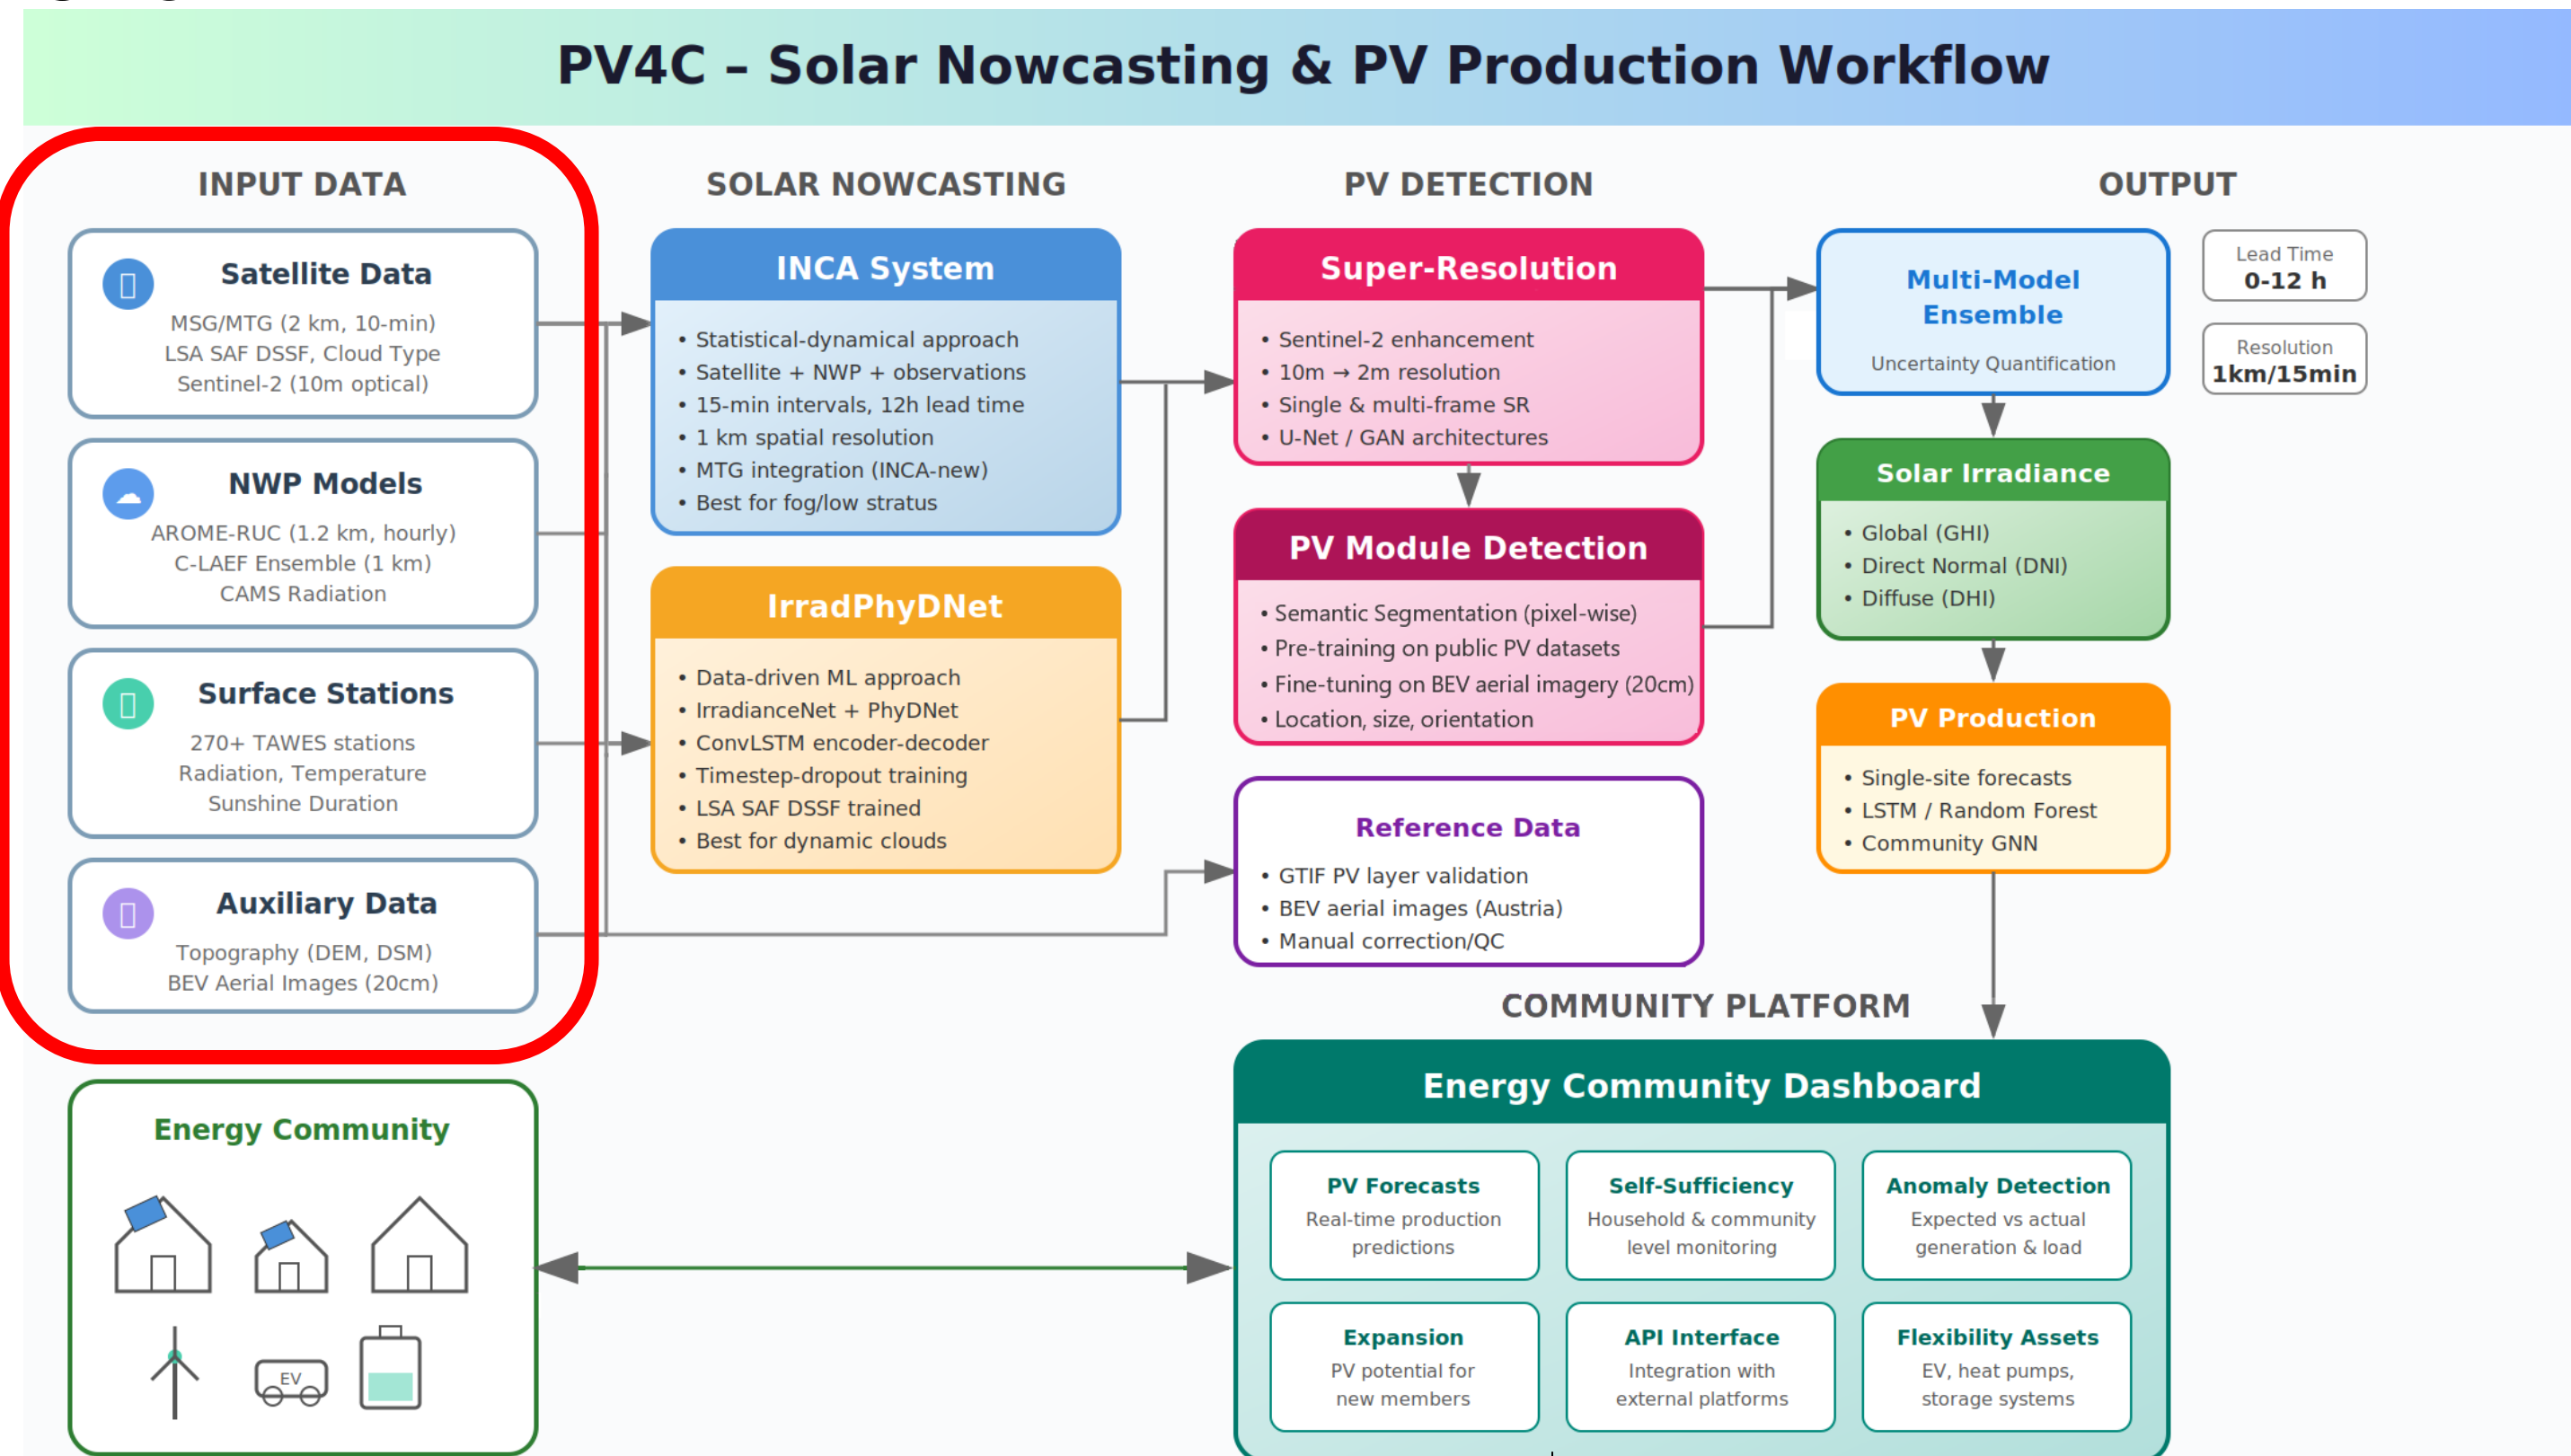
● Herausforderungen in Energiegemeinschaften

- Energiegemeinschaften teilen dezentrale PV-Erzeugung
- Hohe Variabilität der PV-Produktion erschwert Planung
- Zeitliche Diskrepanz zwischen PV-Produktion (mittags) und Verbrauch (morgens/abends)
- Fehlende hochaufgelöste, automatisierte Prognosen
- Bedarf an operativ nutzbaren Vorhersagen für:
 - Eigenverbrauch
 - Netzstabilität
 - Flexibilitätsnutzung



Methodischer Workflow

Gesamtübersicht



Input Datenquellen

● PV-Panel Detektion

- BEV-Luftbilder (Österreich): ortho-entzerrt, UltraCam, RGB + NIR, 20 cm Bodenaufklärung
- Öffentliche PV-Datensätze, z.B. BDAPPV, SolarDE, SolarDK (manuell gelabelte Dach-PV)
- Regionale BEV-Zusatzlabels: manuelle Annotationen für österreichische Dach- und Bautypen
 - Mehrere Aufnahmezeitpunkte: Abbildung zeitlicher Änderungen und neuer PV-Installationen

BEV: Bundesamt für Eich- und Vermessungswesen

● INCA (Legacy & New)

- AROME-NWP-Modell: 2.5 km Auflösung
- MSG-Satellitendaten: Wolkentyp Level 2
- TAWES-Messnetz: > 270 Stationen (Globalstrahlung, Sonnenscheindauer)
- C-LAF-Ensemble: 1 km, stündlich; MTG (2 km, 10 min), CAMS-Strahlungsdaten

● IrradPhyDNet

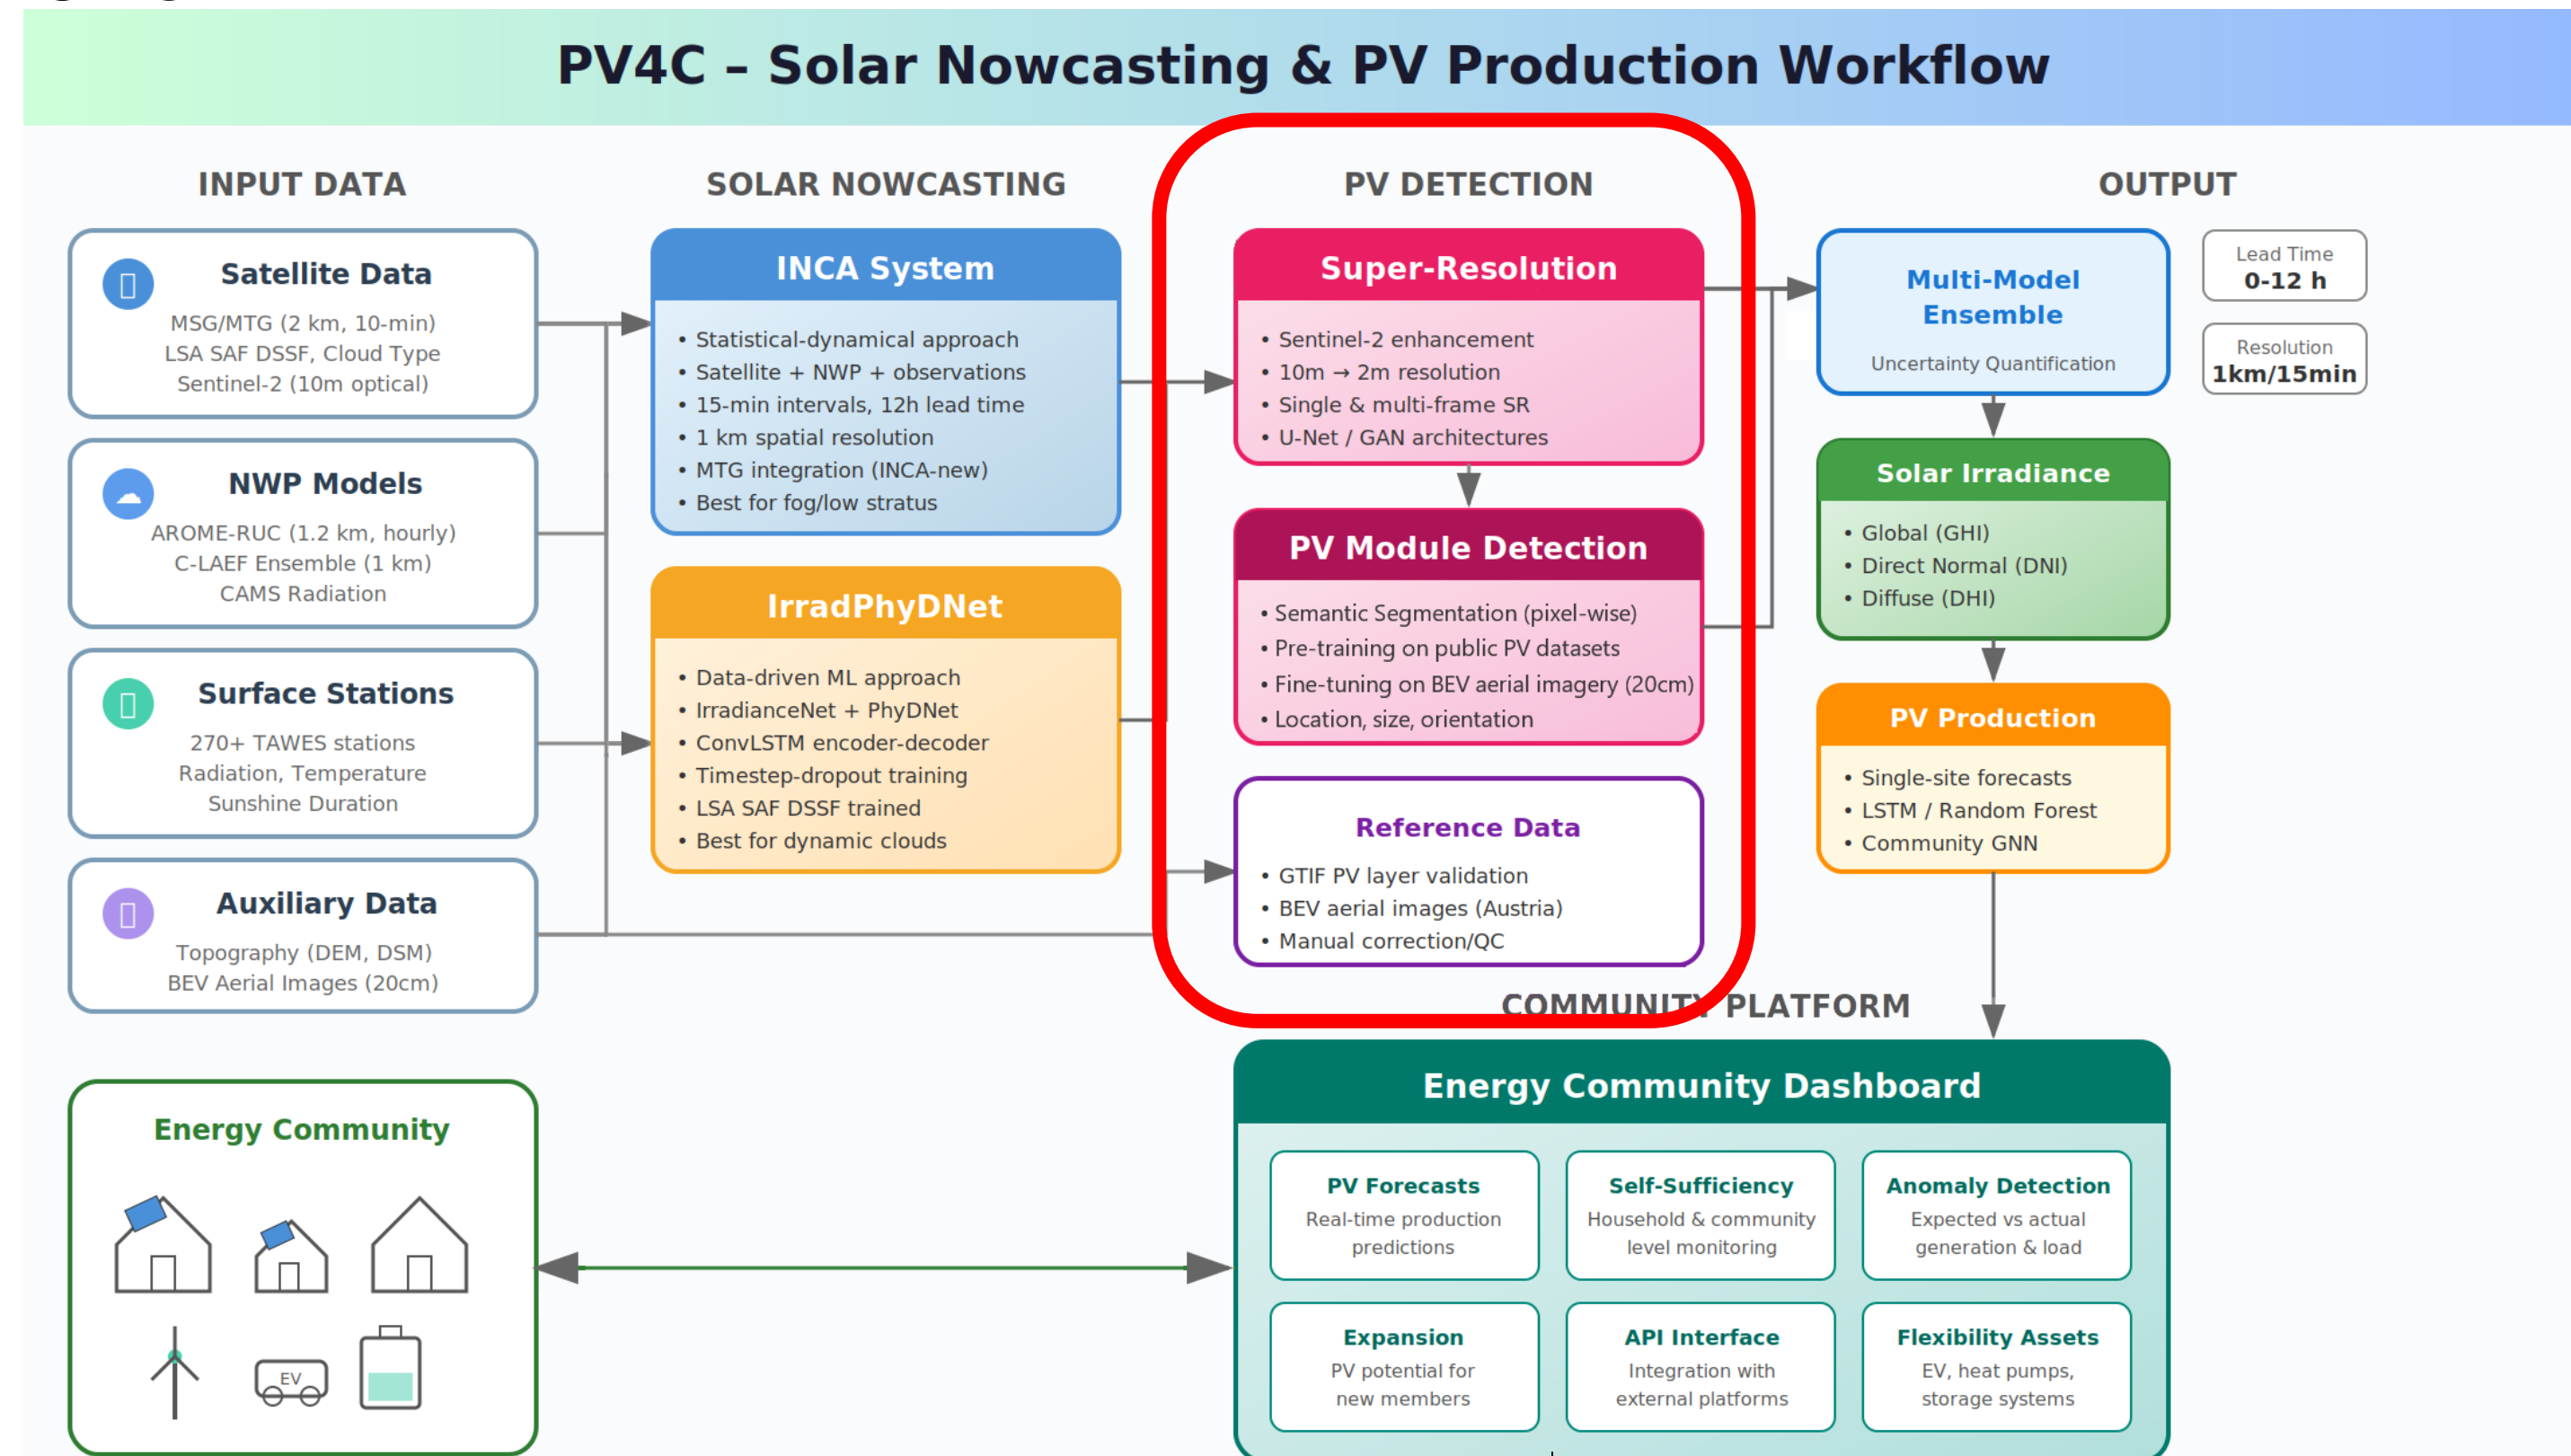
- LSA SAF DSSF: globale Einstrahlung aus MSG-Satellitendaten
- Topographische Informationen: Digitale Höhenmodelle (DEM)
- Zeitkodierte Merkmale: zyklische Datums-/Zeitinformationen für Tagesgänge

● PV-Erzeugungsprognose

- Historische PV-Erzeugungsdaten
- Nowcasting- und numerische Modellvorhersagen
- Meteorologische Beobachtungsdaten
- Anlagenmetadaten: Standort, technische Spezifikationen

Methodischer Workflow

Gesamtübersicht



PV-Panel Detektion

Ansatz & Modelle

Ziel

- Erkennung von PV-Anlagen
- Grundlage für Kapazitätsschätzung

Evaluierte Detektionsansätze

- Binäre Klassifikation auf Bildausschnitt-Ebene (224x224)
 - Inception-V3, EfficientNet
- Objekterkennung mit Bounding Boxes (BBox)
 - YOLOR
- Pixelweise semantische Segmentierung
 - U-Net, U-Net++, SegFormer

Modellauswahl

- Fokus auf Segmentierung
- Evaluierte Architekturen: U-Net, U-Net++, SegFormer
- Mask R-CNN als Benchmark (GeoAI Model) für Cross-Domail-Analyse

Binäre Klassifikation (ja/nein)



BEV Orthophoto www.bev.gv.at

Bounding Box Detektion



Semantische Segmentierung



PV-Panel Detektion


Trainingsdaten & Domain Shift

Zieldomäne

- Österreichische Luftbilder (Bundesamt für Eich- und Vermessungswesen - BEV)


Herausforderungen

- Starker Domain Shift
 - Sensorik & Auflösung
 - Aufnahmewinkel & Saison
 - Regionale Dachtypen
- Geringe Übertragbarkeit öffentlicher Datensätze
 - Geometrische Verschiebungen (keine True-Orthophotos)



Konsequenz

- Öffentlich verfügbare Labels → unzureichend
- Bedarf an BEV-spezifischen Trainingslabels



PV-Panel Detektion

Training & Active Learning

● Trainingsstrategie (mehrstufig)

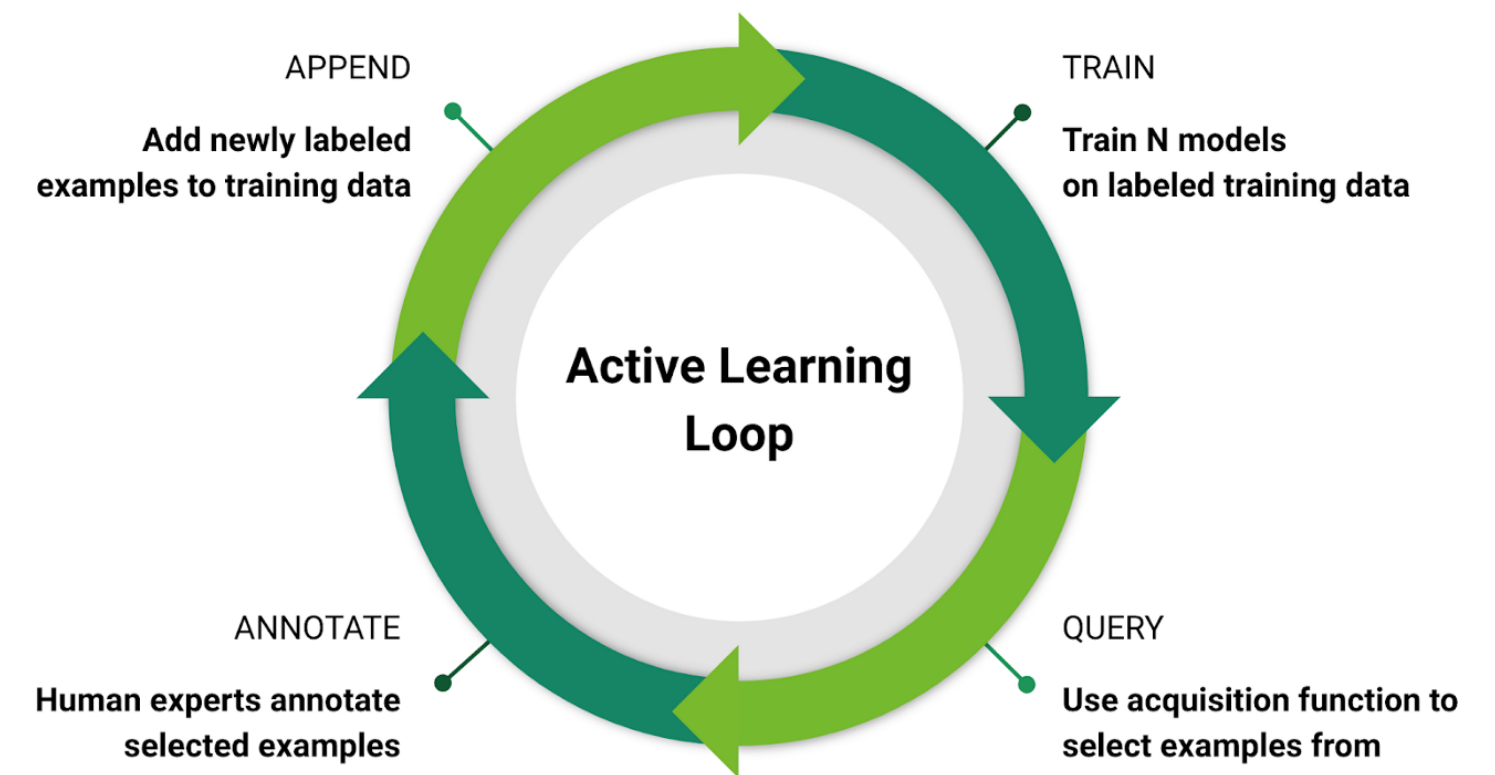
1. Vortraining mit öffentlich verfügbaren PV-Datensätzen
2. Transfer auf BEV-Daten
3. Iteratives Active Learning

● Active Learning

- Auswahl informativer Samples über Modell-Unsicherheit
- Fokus auf U-Net++ & SegFormer
- 7 Active-Learning-Zyklen
 - Manuelle Eingriffe (Zyklus 1 & 4) zur Korrektur von Model Drift
- 50-250 neue Bildausschnitte (Labels) pro Zyklus

● Zwei Active Learning Strategien

- Fortlaufendes Fine-Tuning
- Erneute Re-Initialisierung
 - Analyse von Model Drift



Source: <https://www.cloudfactory.com/blog/active-learning-and-autonomous-vehicles>

PV-Panel Detektion

Visuelle Ergebnisse

Input
(image patch)



SegFormer
(cont. fine-tuning)



SegFormer
(reinitialization)



U-Net++
(cont. fine-tuning)




U-Net++
(reinitialization)



PV-Panel Detektion

Visuelle Ergebnisse

- **Multi-Modell-Agreement (Ensemble Learning)**
 - Höhe Übereinstimmung = robuste Detektion
 - Geringe Übereinstimmung = Unsicherheit
 - Unterstützung für Active Learning & Fehleranalyse

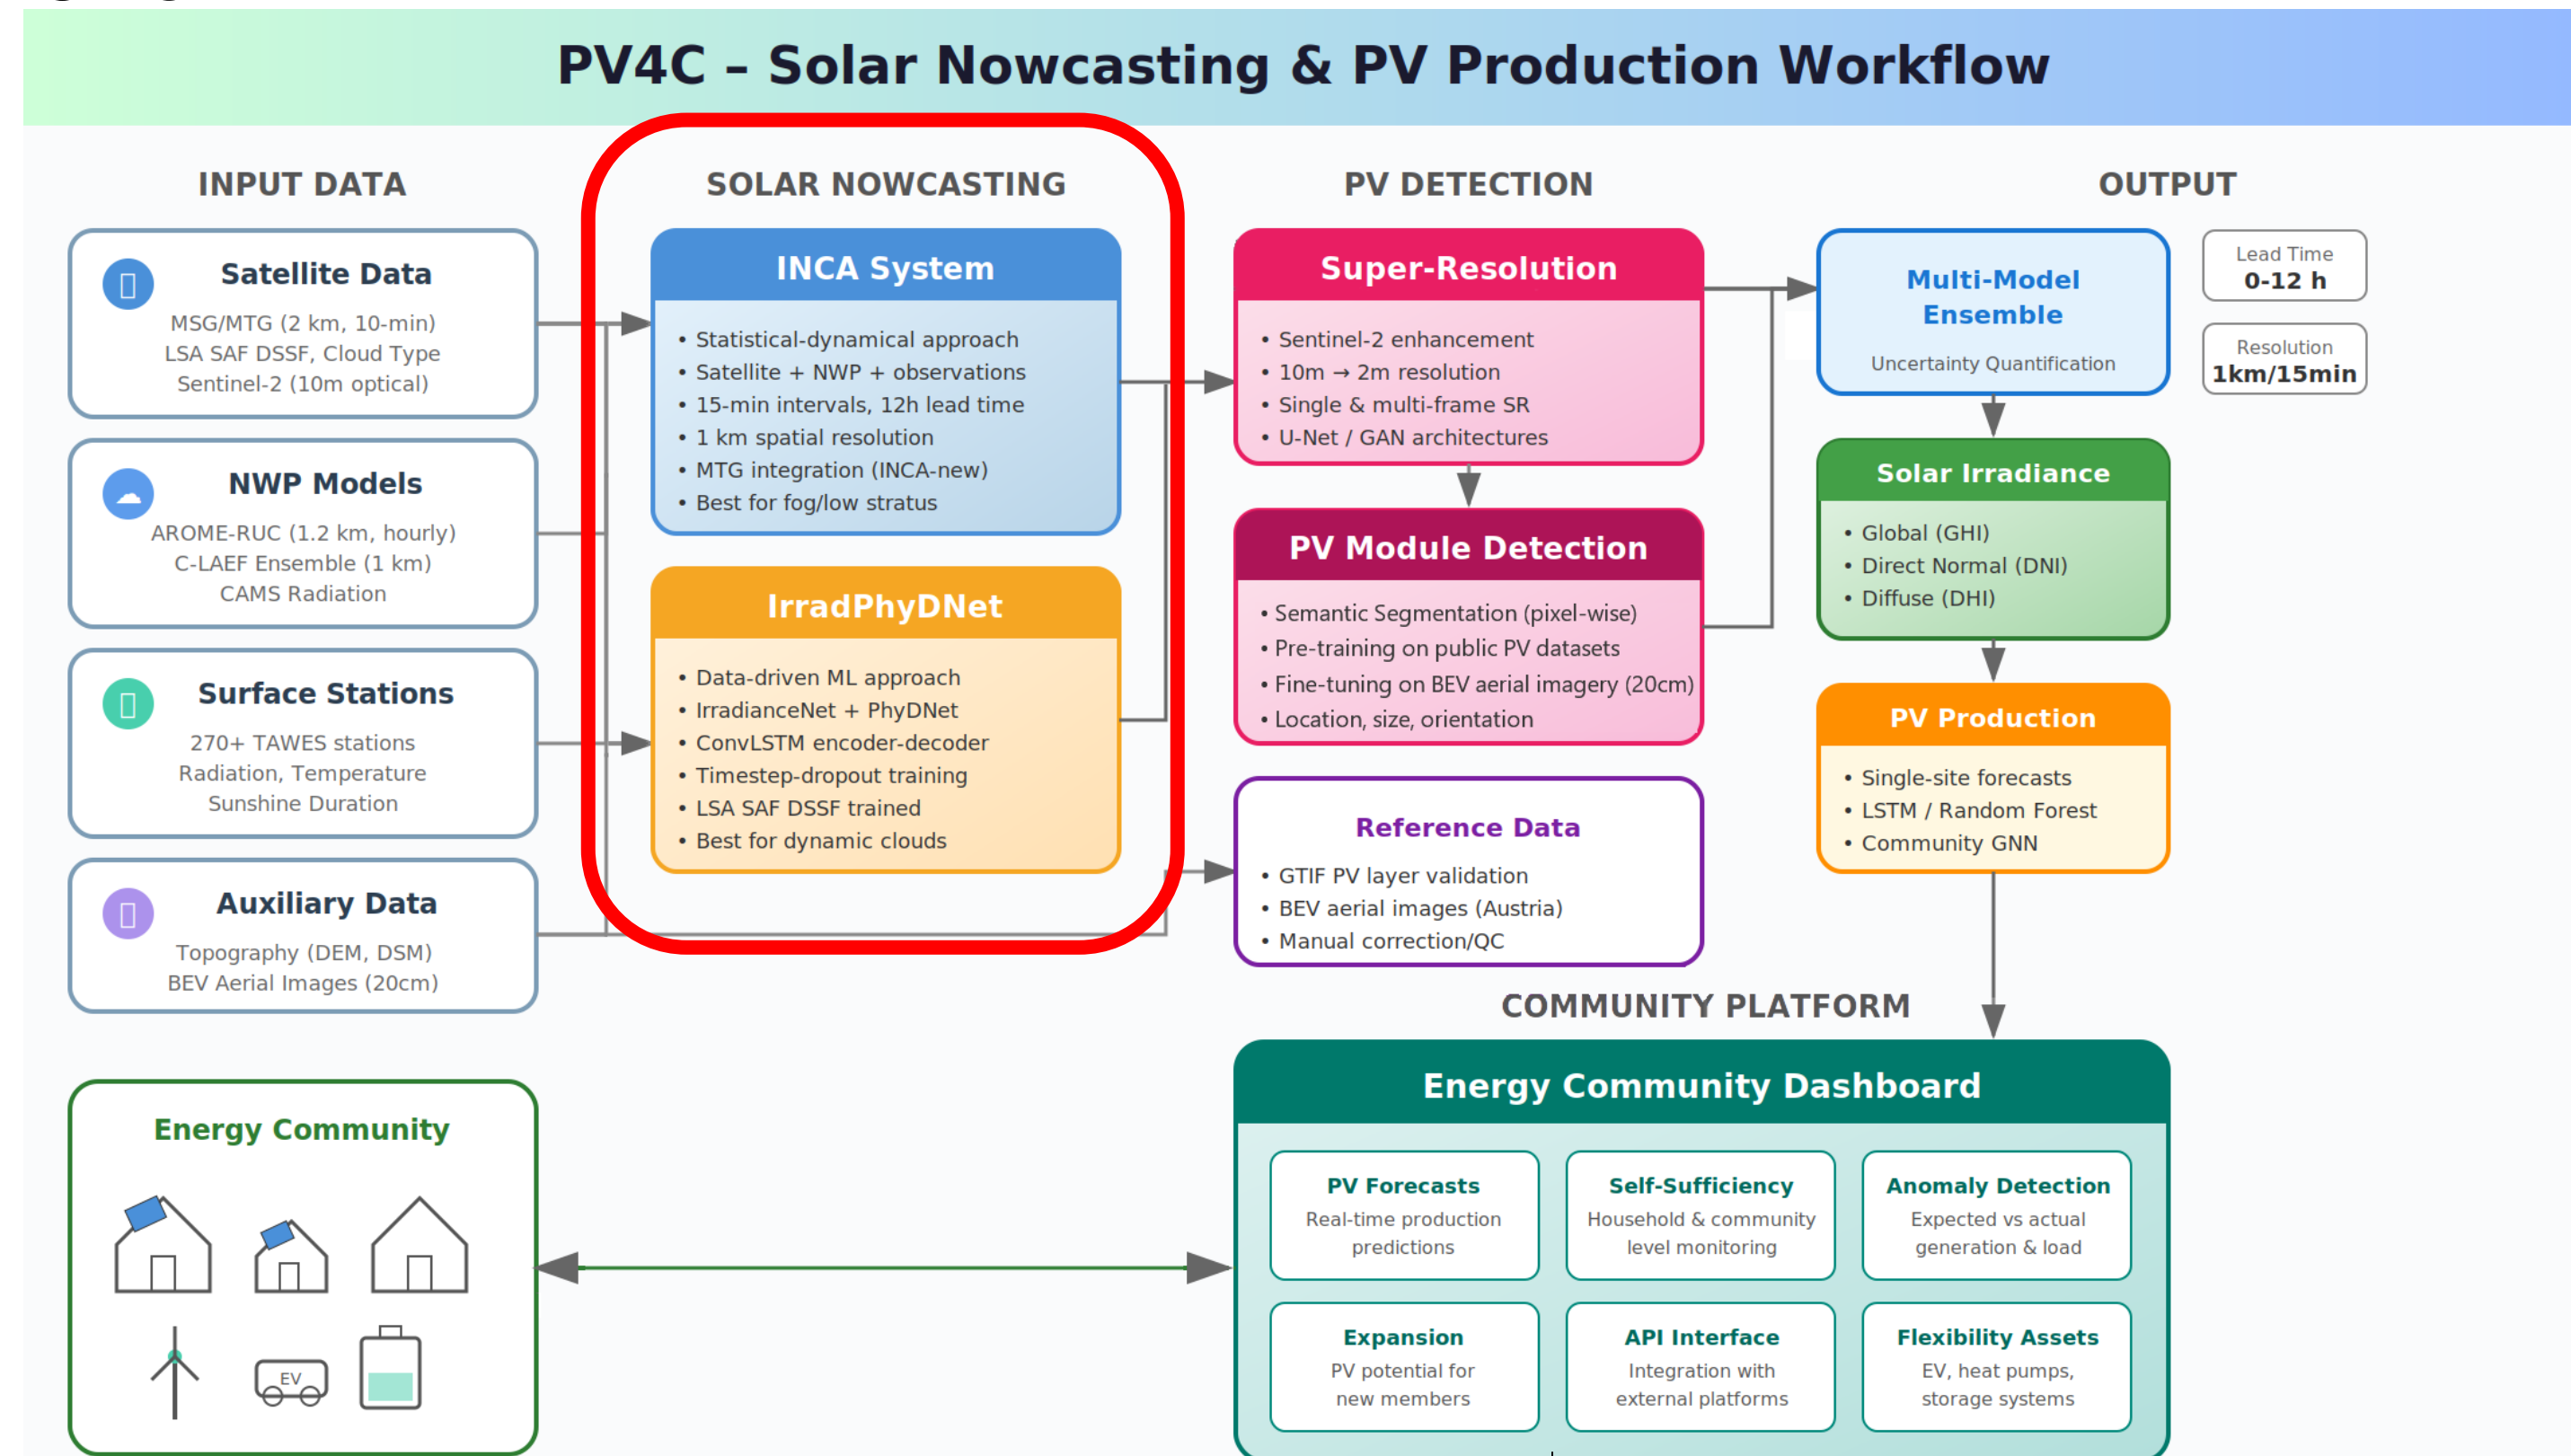


Detection agreement:

- 1 Detected by 1 model
- 2 Detected by 2 models
- 3 Detected by 3 models
- 4 Detected by 4 models

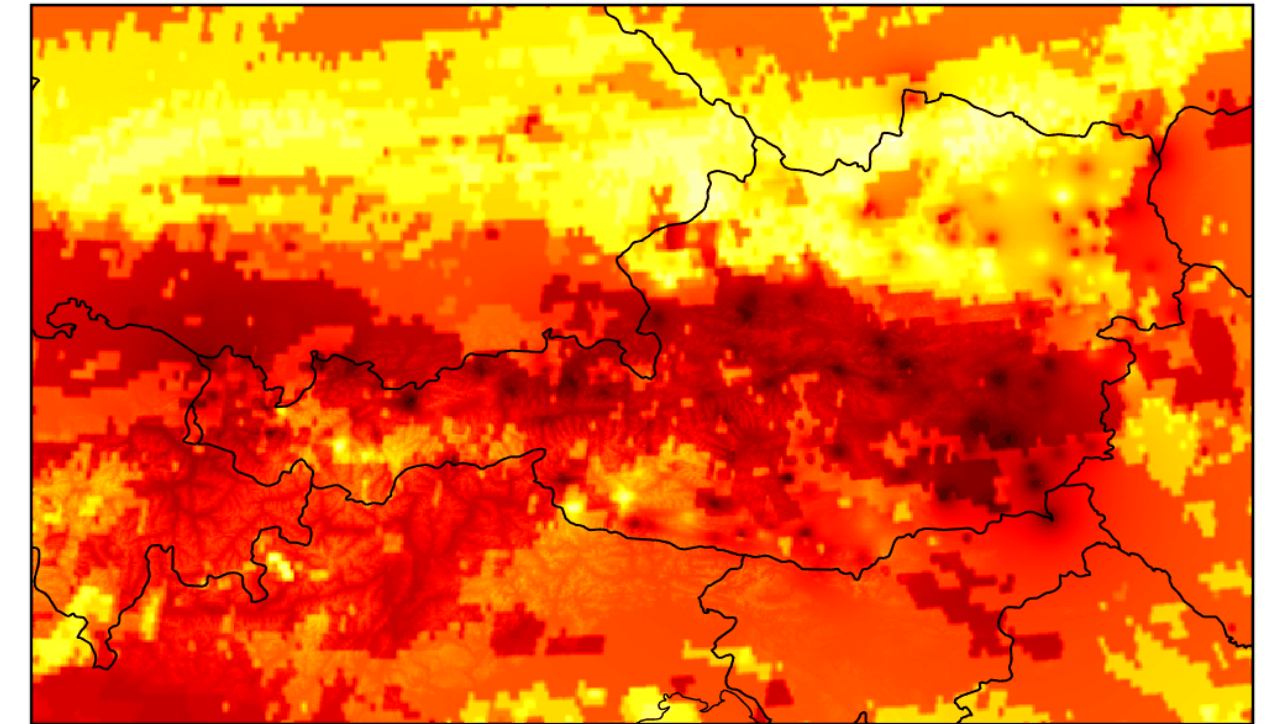
Methodischer Workflow

Gesamtübersicht



Solar Nowcasting INCA System

INCA 2025-05-07T12:15 (+000 min)

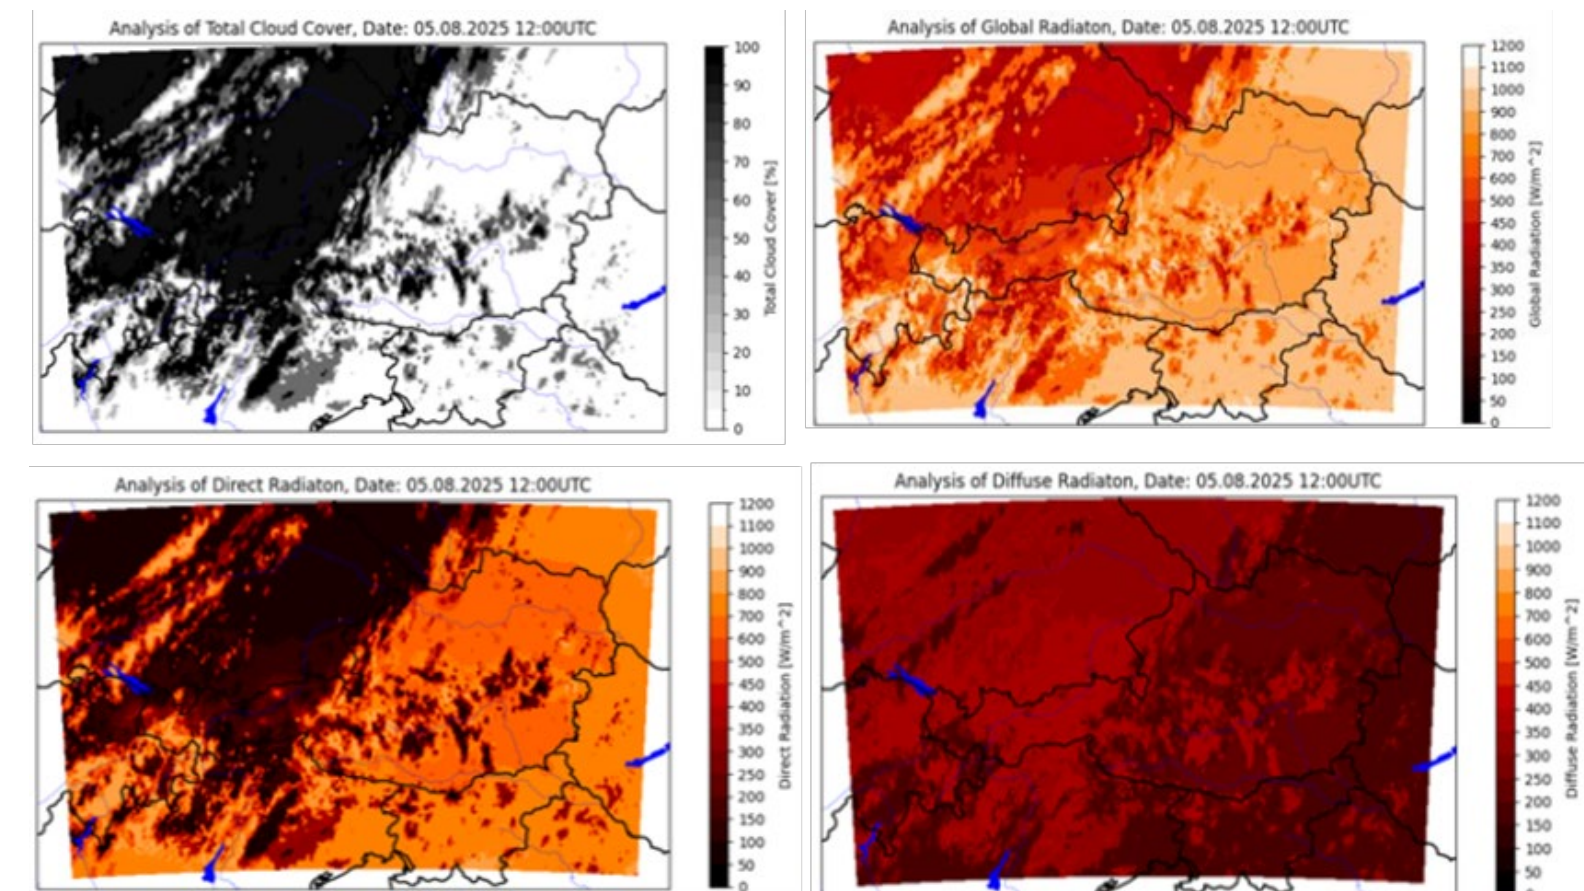
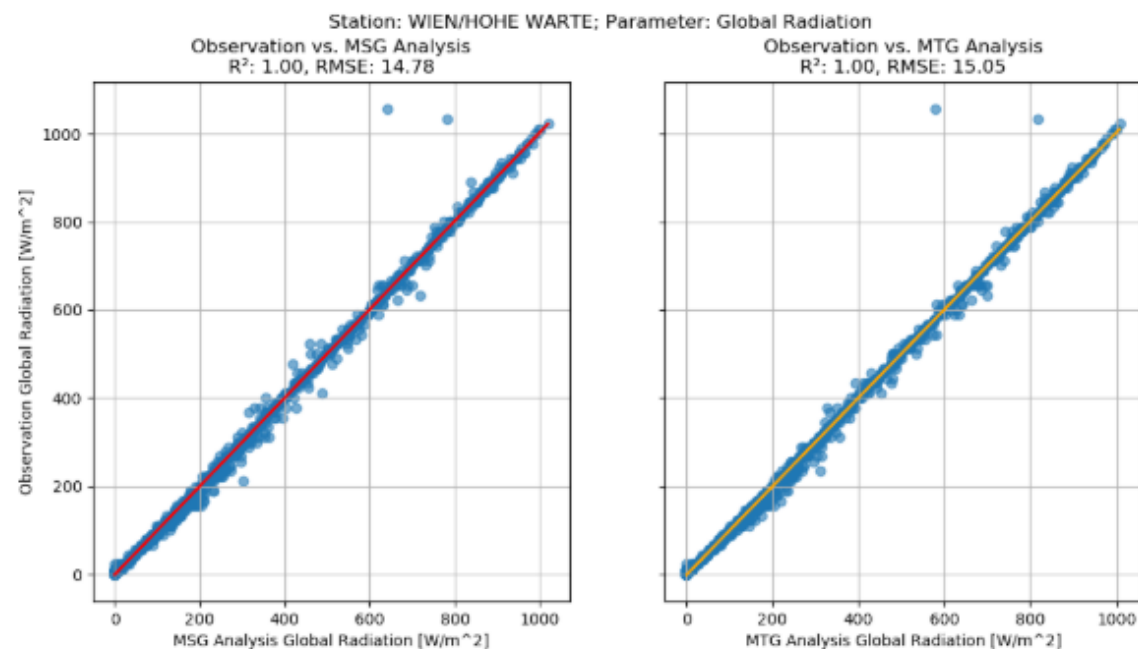


Operational analysis and nowcasts (up to 180 min) of INCA global irradiance on 7.5.2025 (initialization time at 12 UTC) calculated with the old input MSG cloud types and AROME 2.5 km NWP Model as a first-guess.

● Datenbasis und Modellansatz

- Statistisch-dynamisches Nowcasting-System
- Kombination aus C-LAEF-NWP-Modell (1 km, stündlich)
- MTG-Satellitendaten (2 km, 10-min)
- 270+ TAWES-Bodenstationen
- Berechnung von Global-, Direkt- und Diffusstrahlung
- 15-min-Intervalle, Vorhersage bis 24 h

Comparison of 15 min INCA global irradiance analyses with observations at Hohe Warte for a selected test period May-June 2025. The difference in correlation comes from different satellite input, MSG- (left) and MTG FCI cloud types.



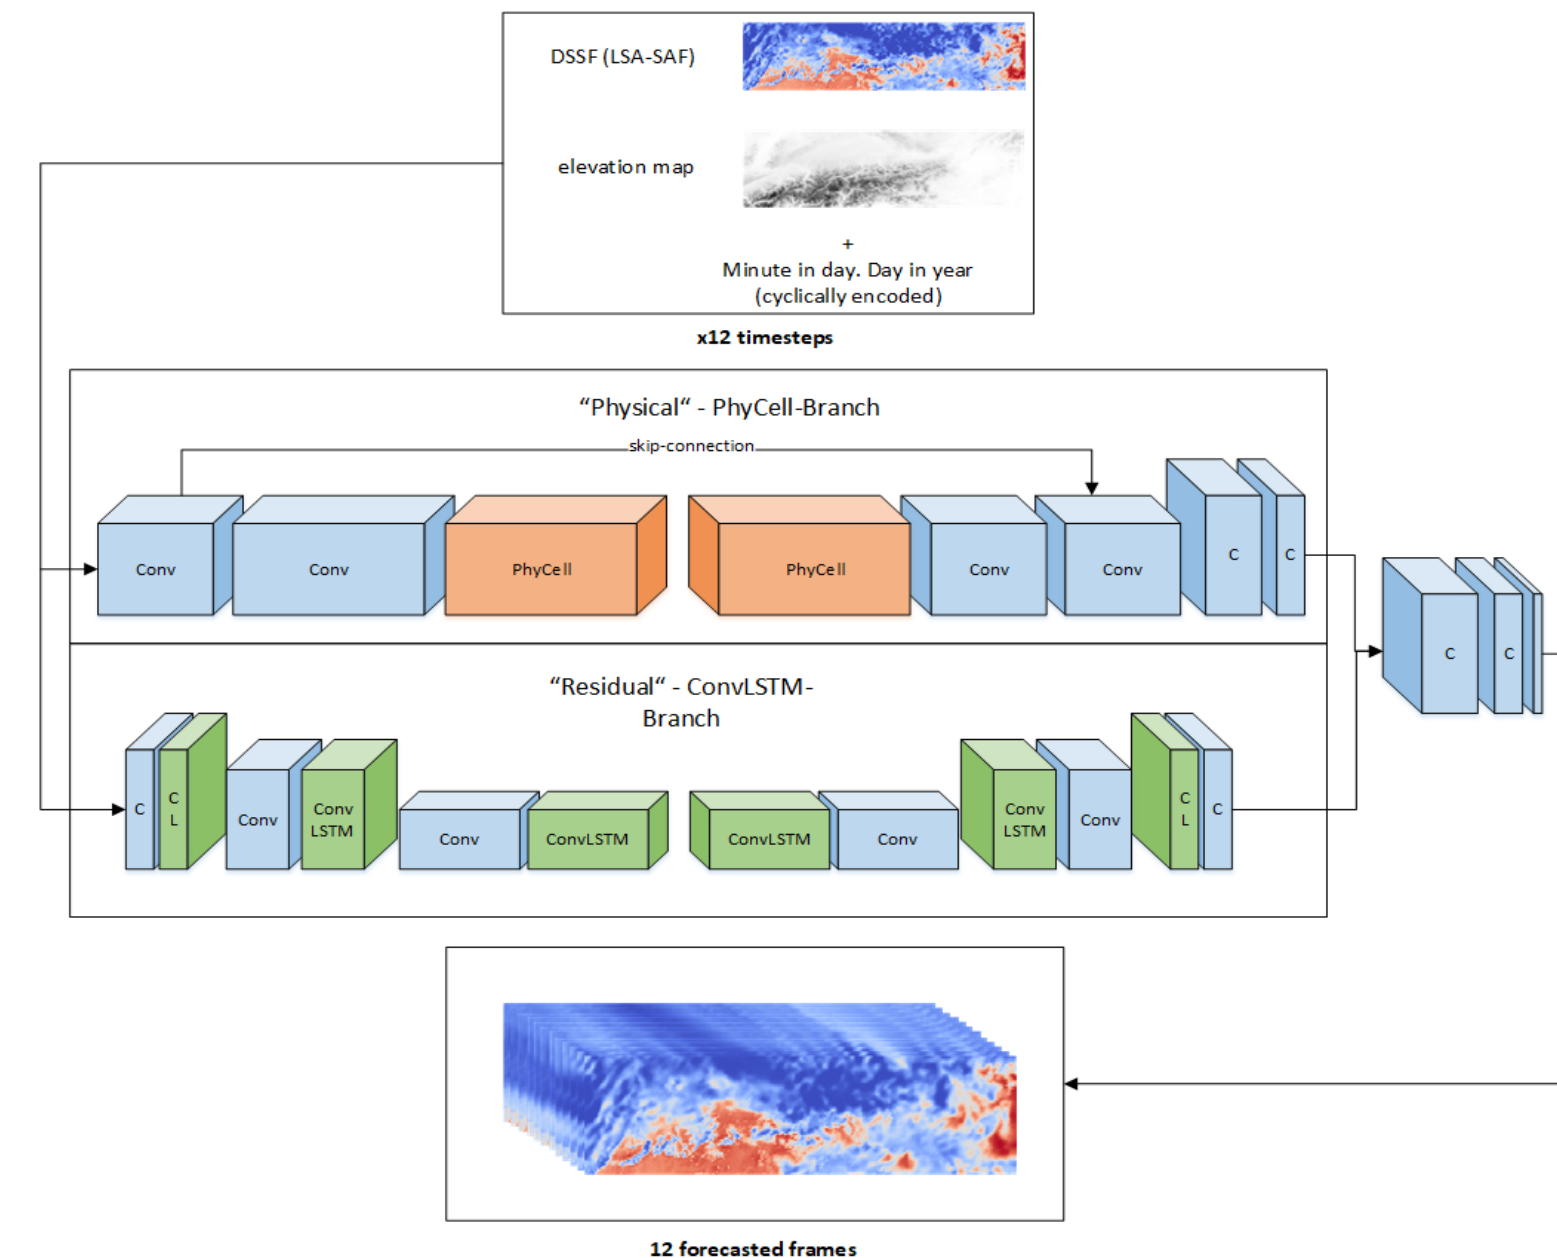
Analysis of cloudiness (upper left) and three radiation components implemented in INCA for 5.8.2025 12 UTC. The analyses are computed with MTG FCI cloud types and C-LAEF 1 km x 1 km NWP Model.

Solar Nowcasting IrradPhyDNet

Datengetriebener Deep-Learning-Ansatz

- Input Daten
 - MSG-/MTG-Satellitendaten
 - Topographische Informationen
 - Zyklisch kodierte Zeitangaben
- ConvLSTM-Encoder-Decoder-Architektur
- Training mit LSA SAF DSSF-Satellitenprodukt
- Timestep-Dropout zur Behandlung fehlender Zeitframes

Architecture of IrradPhyDNet



Equation timestep-dropout

$$\forall T \in X : f(T) = \begin{cases} 0_{T_{m*n}} & \text{if } p < c \\ T & \text{else} \end{cases}$$

X : sample of 12 timesteps T

T : spatial timestep of shape $m * n$

c : constant threshold, $c \in \{0.1, 0.25, 0.5, 0.75\}$


p : pseudo-random number drawn from $U([0.0, 1.0])$

Solar Nowcasting


IrradPhyDNet

07.05.2025 12:15 UTC • Lead time: 15 min

Sat-observation

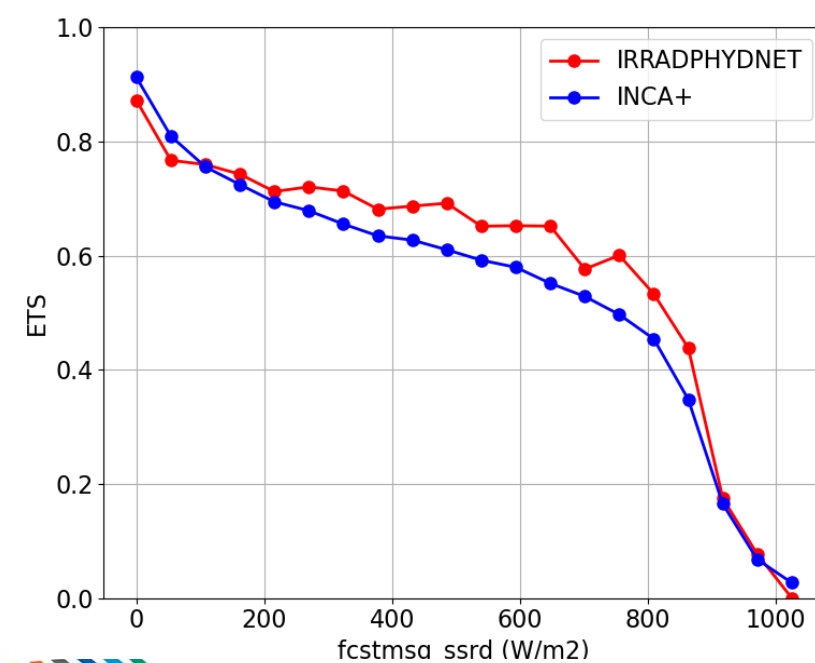


AI-nowcast



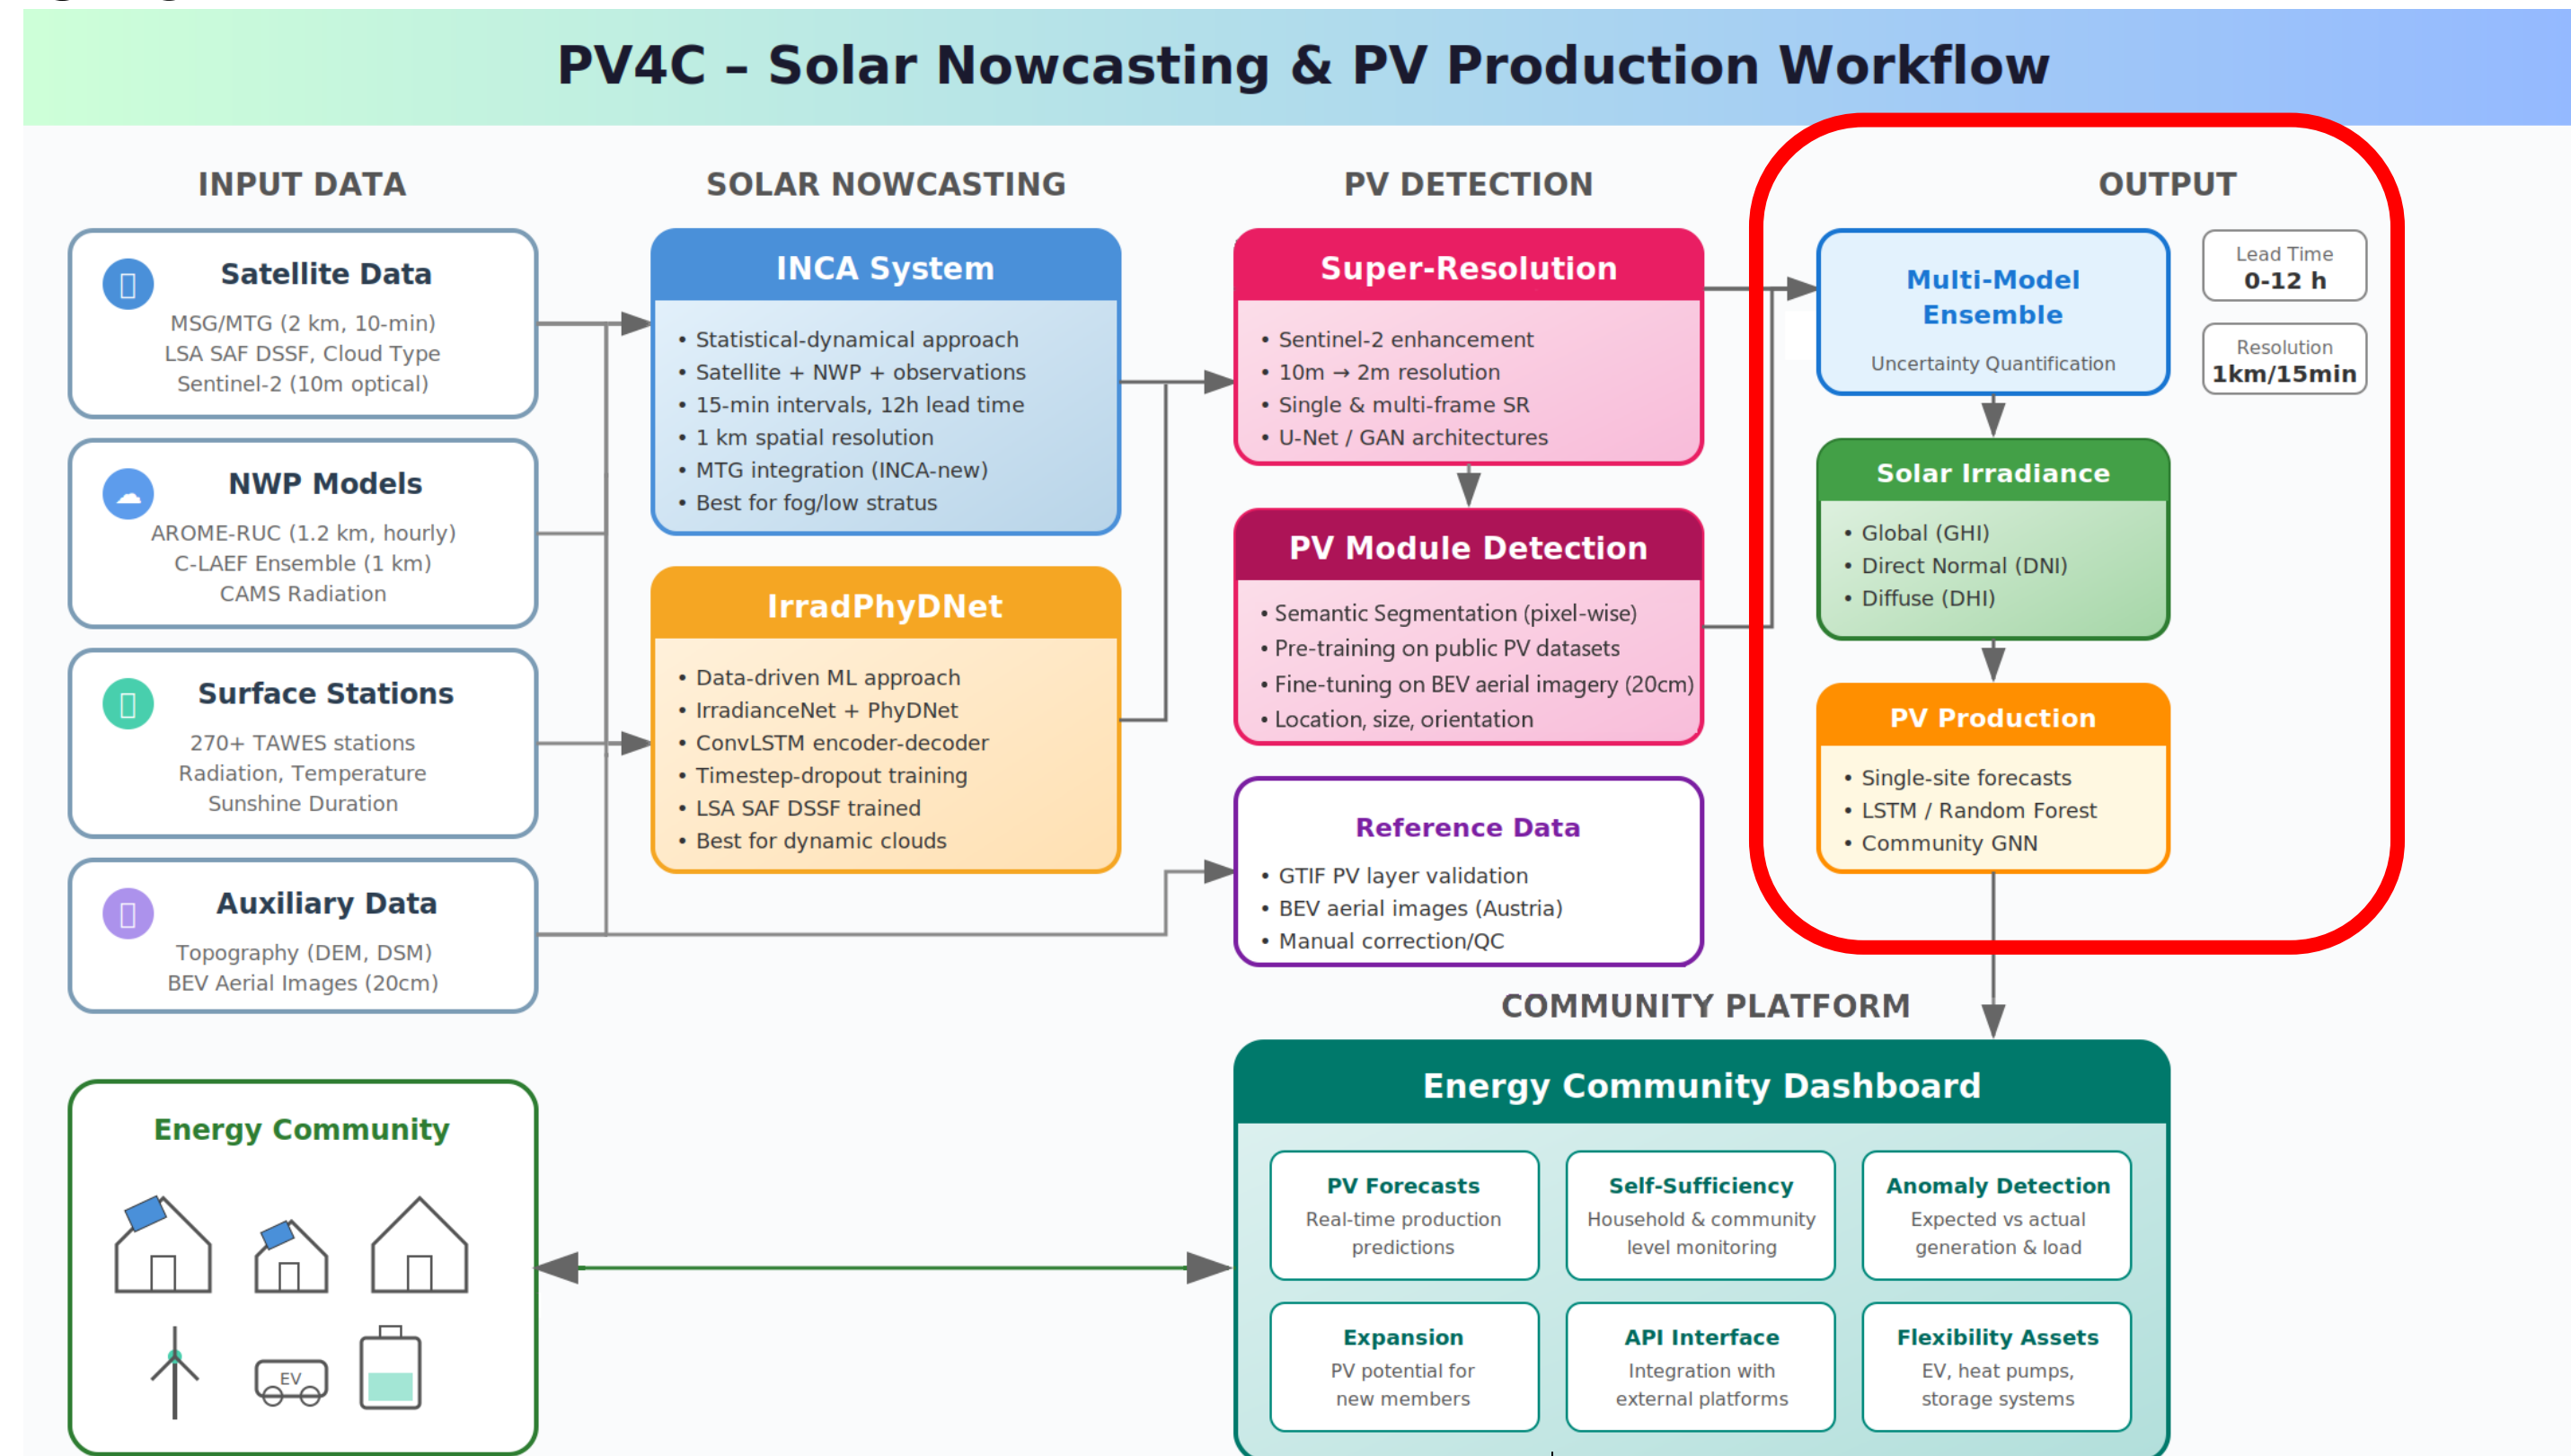
● Datengetriebener Deep-Learning-Ansatz

- Input Daten
 - MSG-/MTG-Satellitendaten
 - Topographische Informationen
 - Zyklisch kodierte Zeitangaben
- ConvLSTM-Encoder-Decoder-Architektur
- Training mit LSA SAF DSSF-Satellitenprodukt
- Timestep-Dropout zur Behandlung fehlender Zeitframes



Methodischer Workflow

Gesamtübersicht

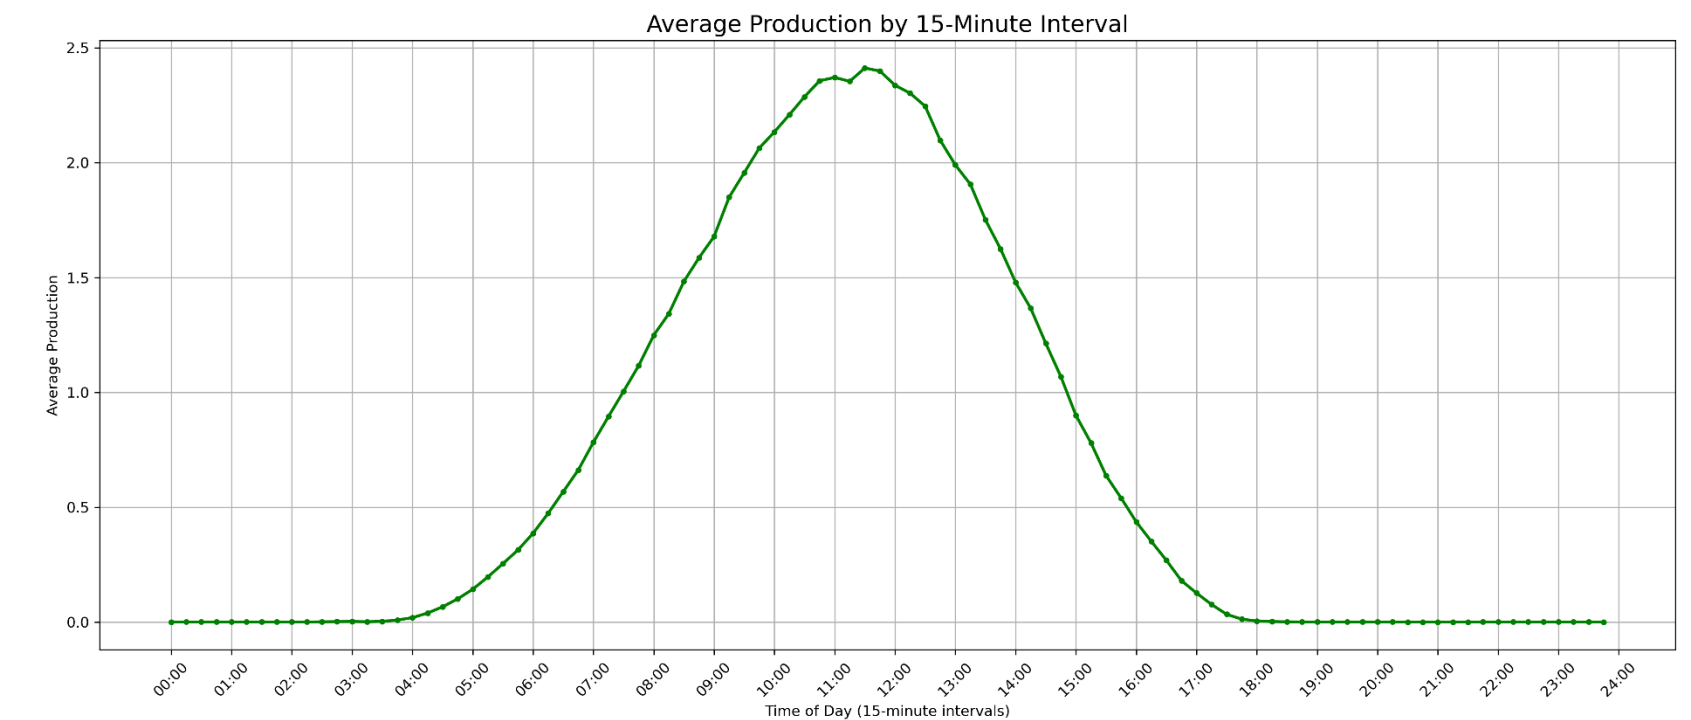
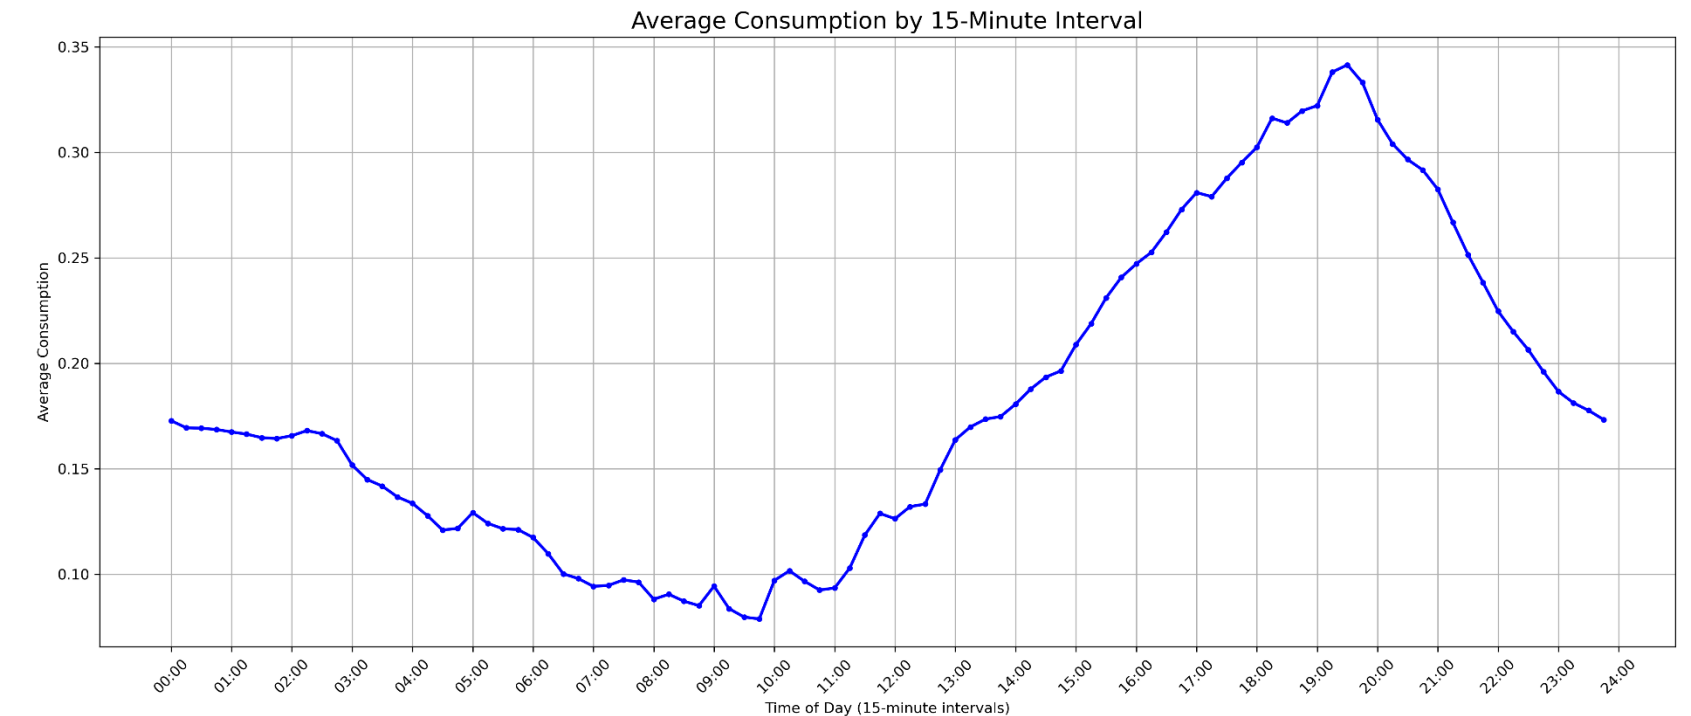


PV-Produktion Prädiktion

Beispiel: Verbrauch und Produktion

Was ist abgebildet?

- Kleine Energiegemeinschaft mit wenigen Erzeugern und mehreren Verbrauchern
- Typische tageszeitliche Muster von Produktion und Verbrauch

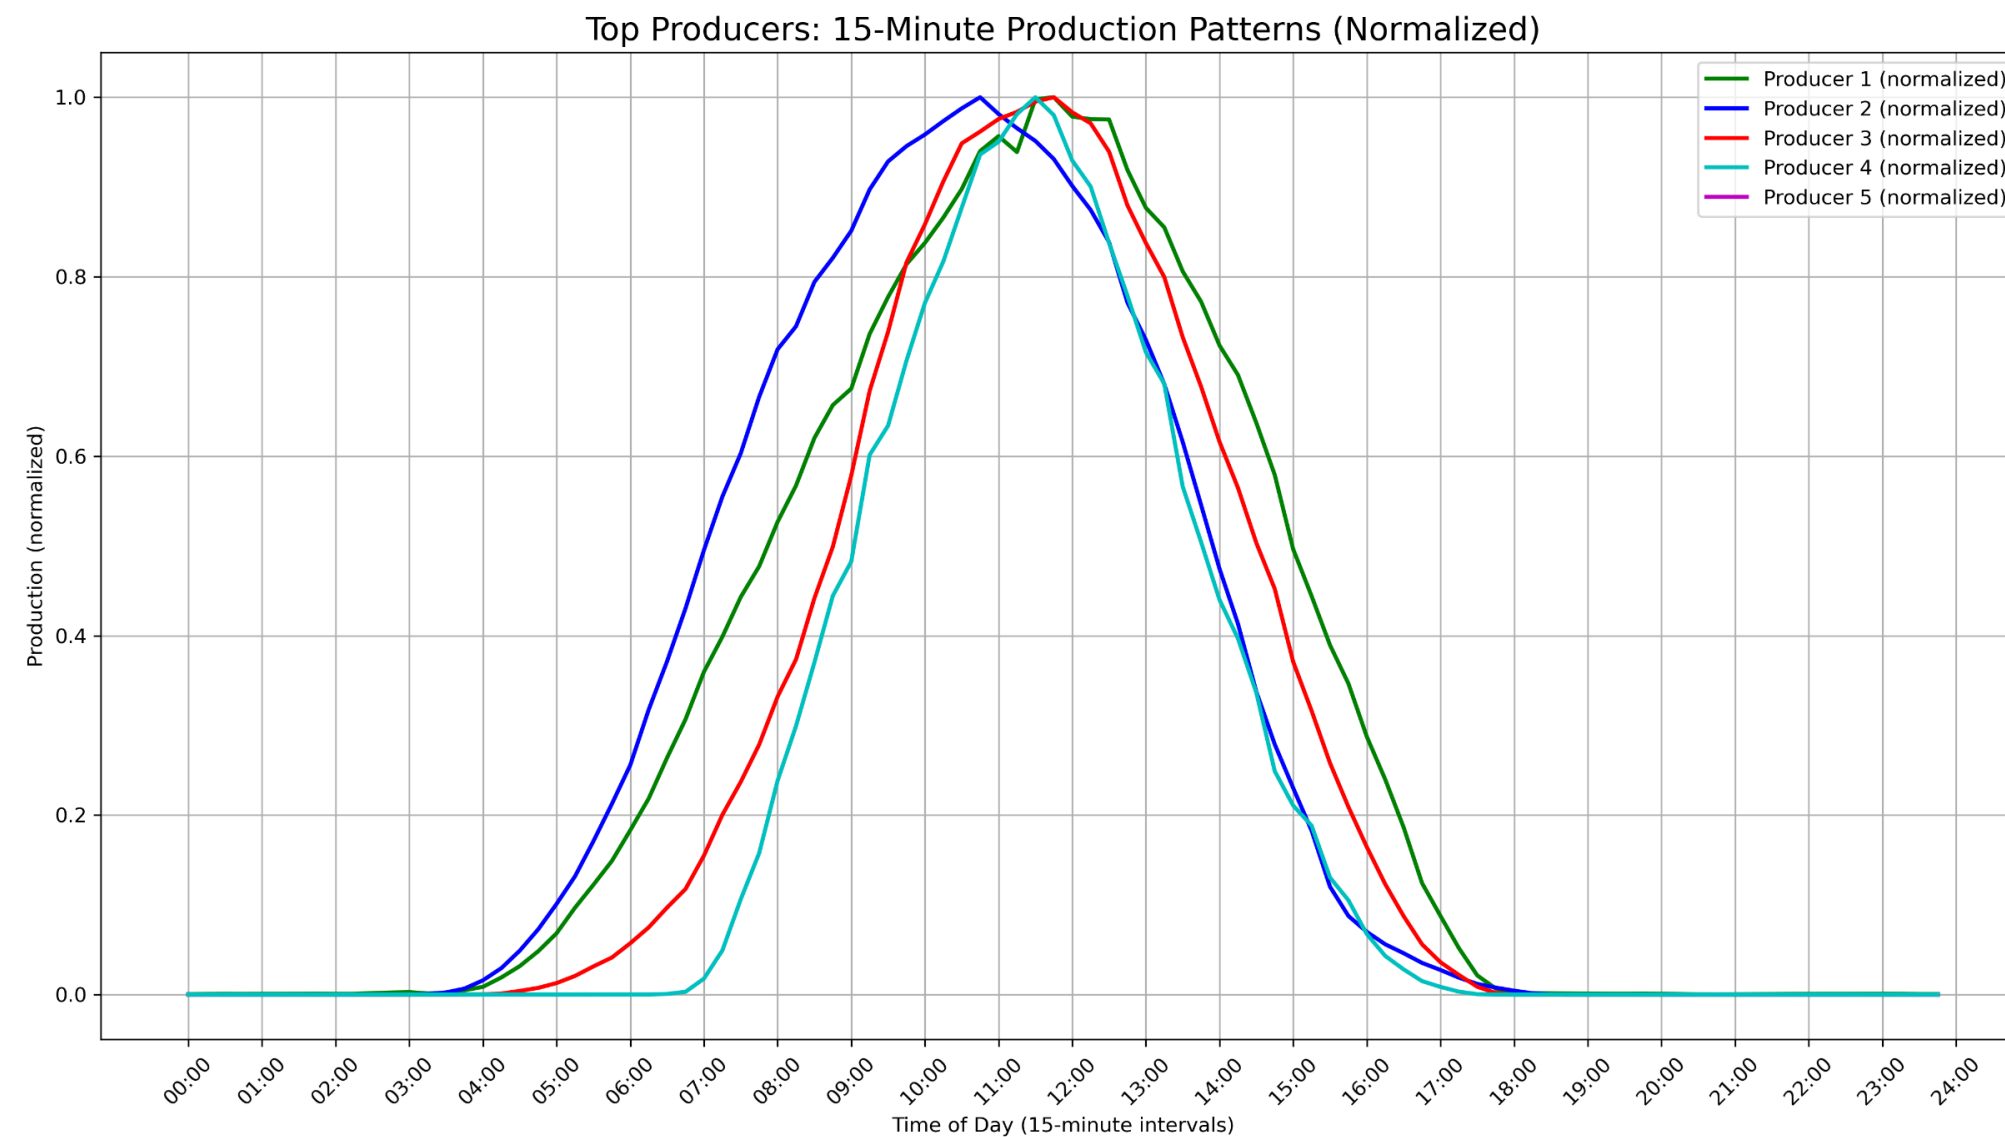



PV-Produktion Prädiktion

Beispiel: Verbrauch und Produktion

Was ist abgebildet?

- Kleine Energiegemeinschaft mit wenigen Erzeugern und mehreren Verbrauchern
- Typische tageszeitliche Muster von Produktion und Verbrauch
- PV-Erzeugung mit klarer Mittagsmaxima
- Zeitliche Verschiebungen bei Erzeugungsbeginn, -Ende und Peak
- Unterschiede deuten auf verschiedene PV-Ausrichtungen und -Installationen hin




PV-Produktion Prädiktion

Beispiel: Forecasting

● Beispielanwendung

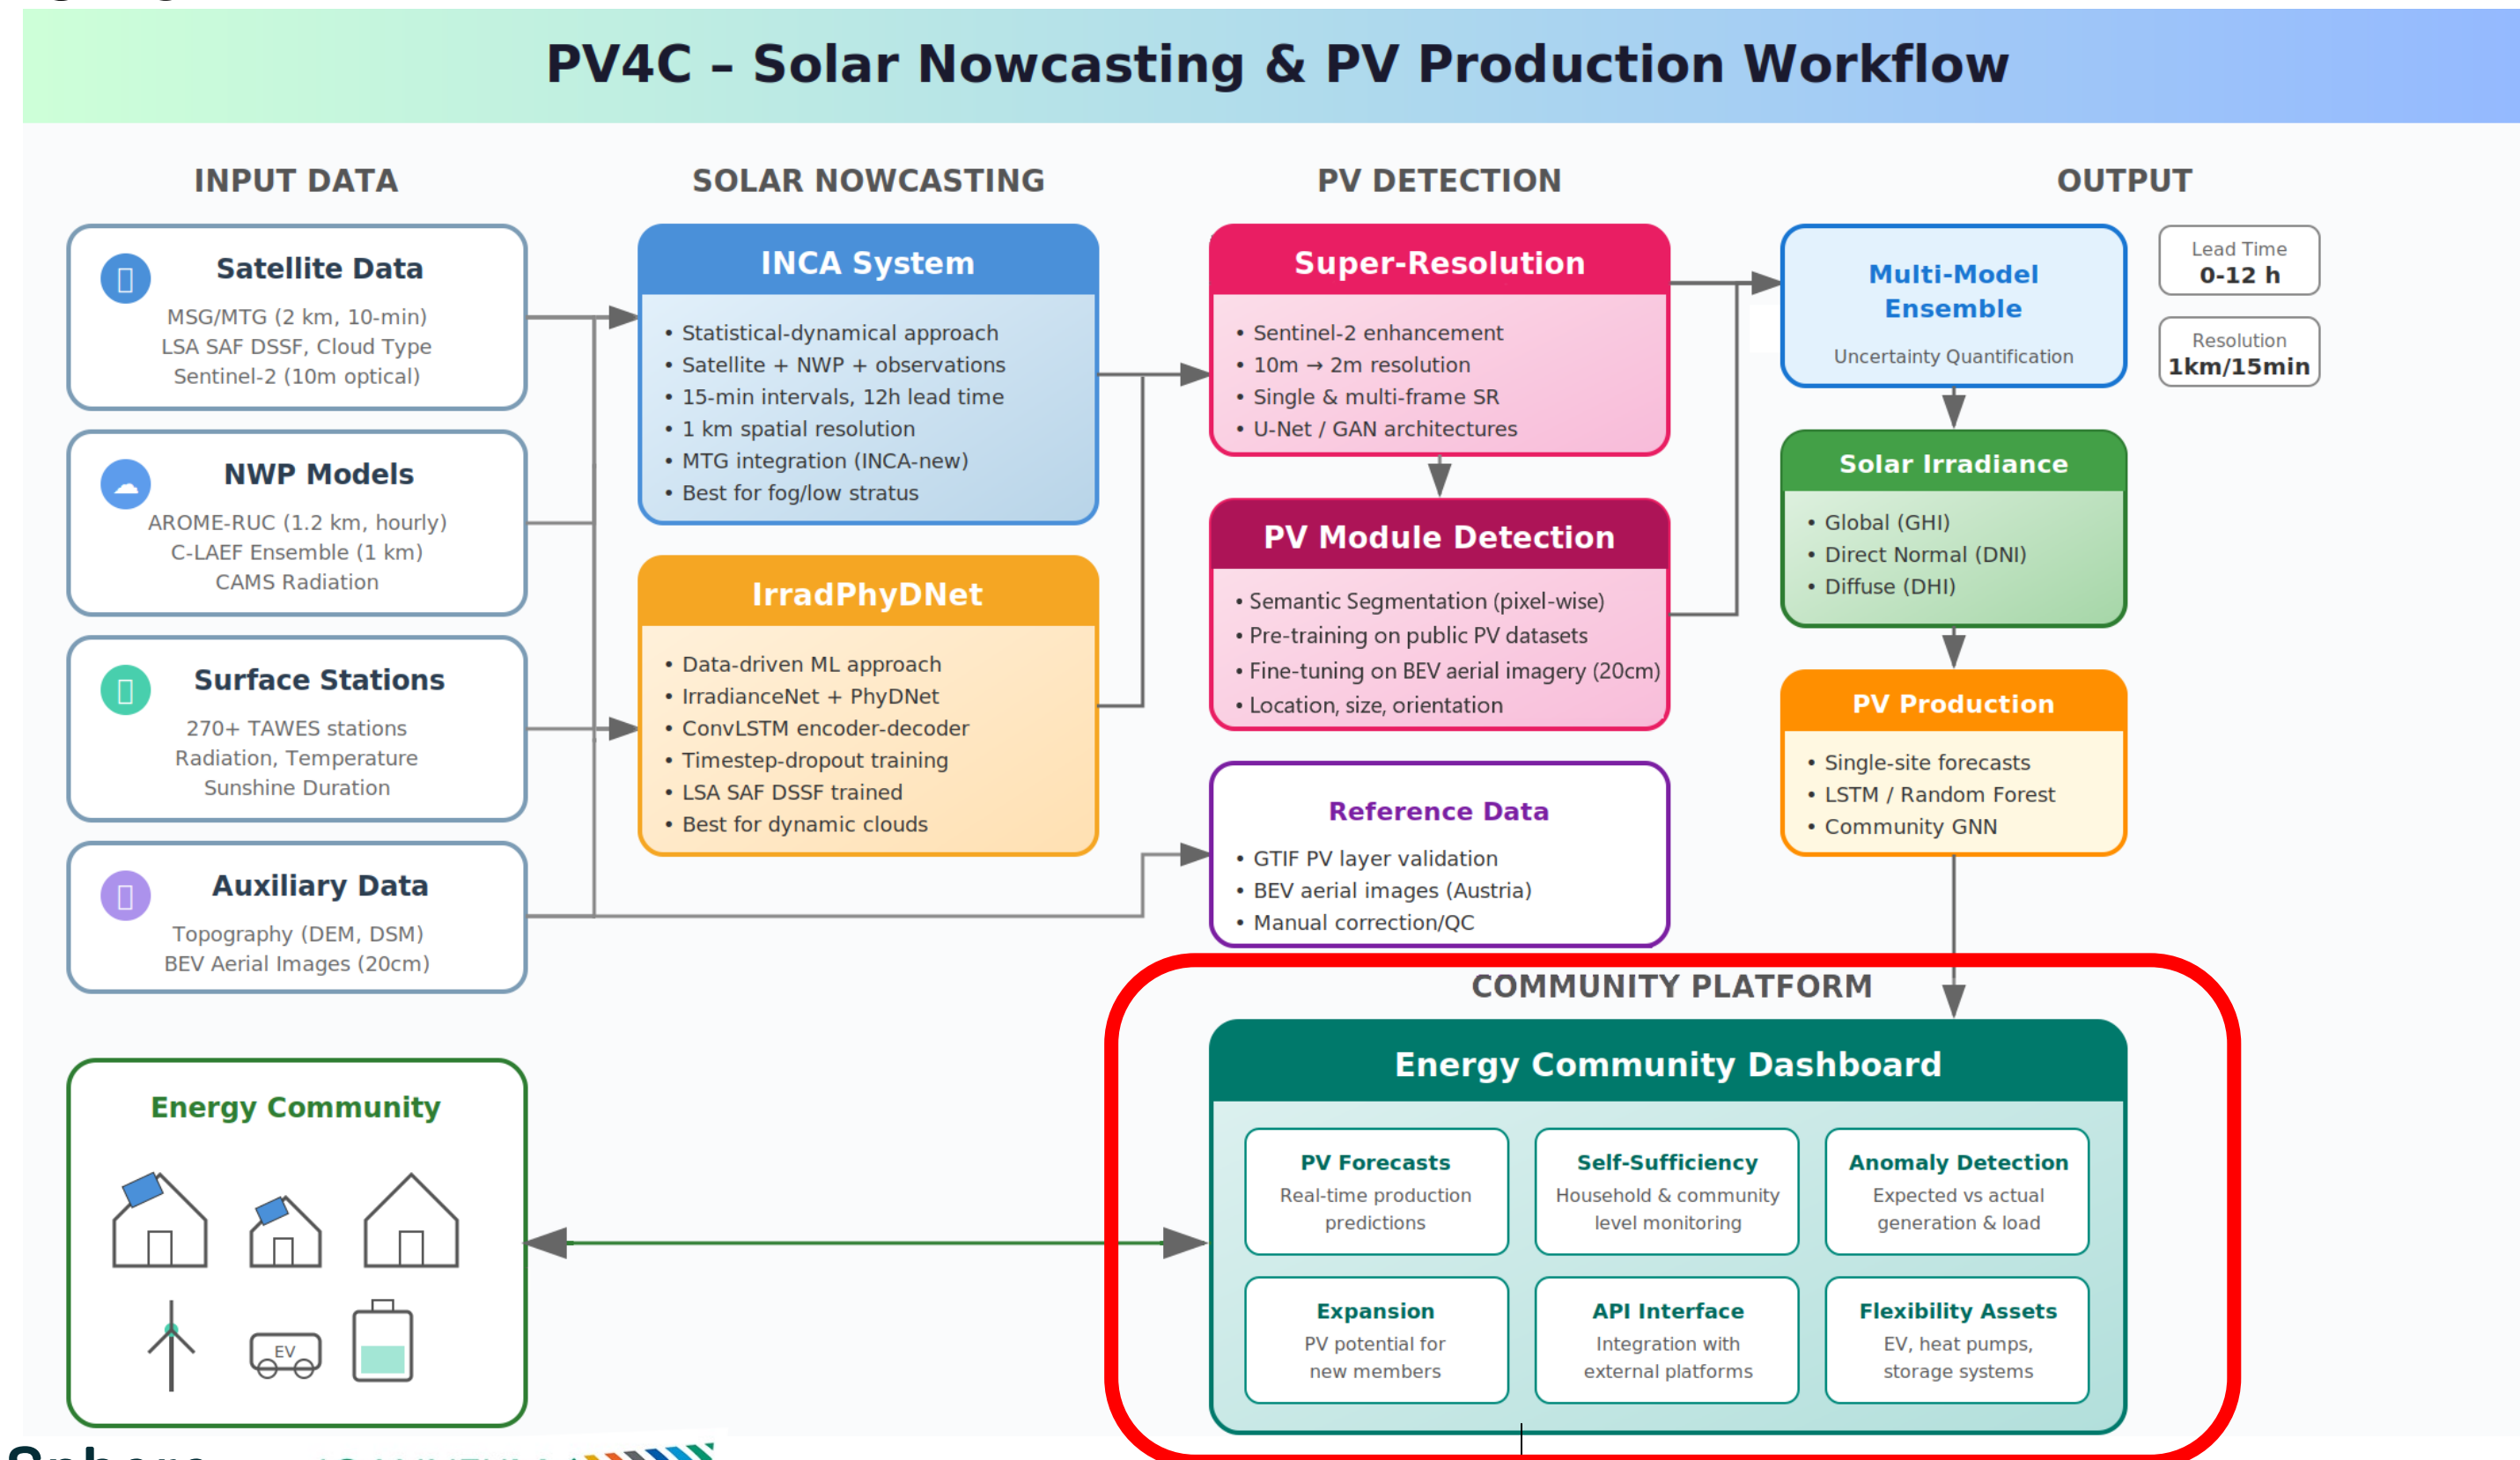
- Beispieldarstellung für einen Standort mit Near-Real-Time-Datenzugang
- Vergleich von Messdaten und Modellvorhersage
- Darstellung von PV-Leistung, Tagesenergie und Peak
- Wetterereignis: Schnee & gefrierender Regen (Wien)
- 24-h-Vorhersagehorizont mit laufender Aktualisierung

Example forecast for a site with near-real time access for the snow & freezing rain event in Vienna



Methodischer Workflow


Gesamtübersicht



Dashboard

Beispiel


Gesamte Energiegemeinschaft



Messwerte für gesamte Energiegemeinschaft

PV-Prognose

Résumé – Mehrwert von PV4C



Präzise PV- Erzeugungsprognosen

Basierend auf Satellitendaten,
Wetterdaten und KI-Modellen
(GNN, Transformer)




Echtzeit Abweichungs- und Anomalieerkennung

Vergleich von erwarteter und
tatsächlicher Erzeugung sowie
Last




Monitoring der Eigenversorgung

Transparente Nachverfolgung
auf Haushalts- und
Gemeinschaftsebene



Intelligente Erweiterungsplanung

Unterstützung beim
Onboarding von Mitgliedern
mit PV-Potenzial



Aktivierung von Flexibilitätsressourcen

Integration von E-Ladestationen,
Wärmepumpen und
Speichersystemen



API- und Dashboard- Schnittstellen

Bereit zur Integration in lokale
Energie- und kommunale
Plattformen



PV4C legt die Grundlage für **datengetriebene Energiegemeinschaften**, erschliesst neue Wertschöpfung aus dezentralen erneuerbaren Energien und bereitet den Weg für **flexible, resiliente und Bürger:innen orientierte** lokale bzw. Regionale Energiesysteme.

Danke für Ihre Aufmerksamkeit

Irene Schicker

Nikta Madjdi

Pascal Gfäller

Matthias Schlögl

Matthias Göbel

Petrina Papazek

Jasmina Hadzimustafic

Roland Perko

Sead Mustafic

Lukas Prenner
Doris Oberleiter



Dieses Projekt wird aus Mitteln
der FFG gefördert. www.ffg.at

