

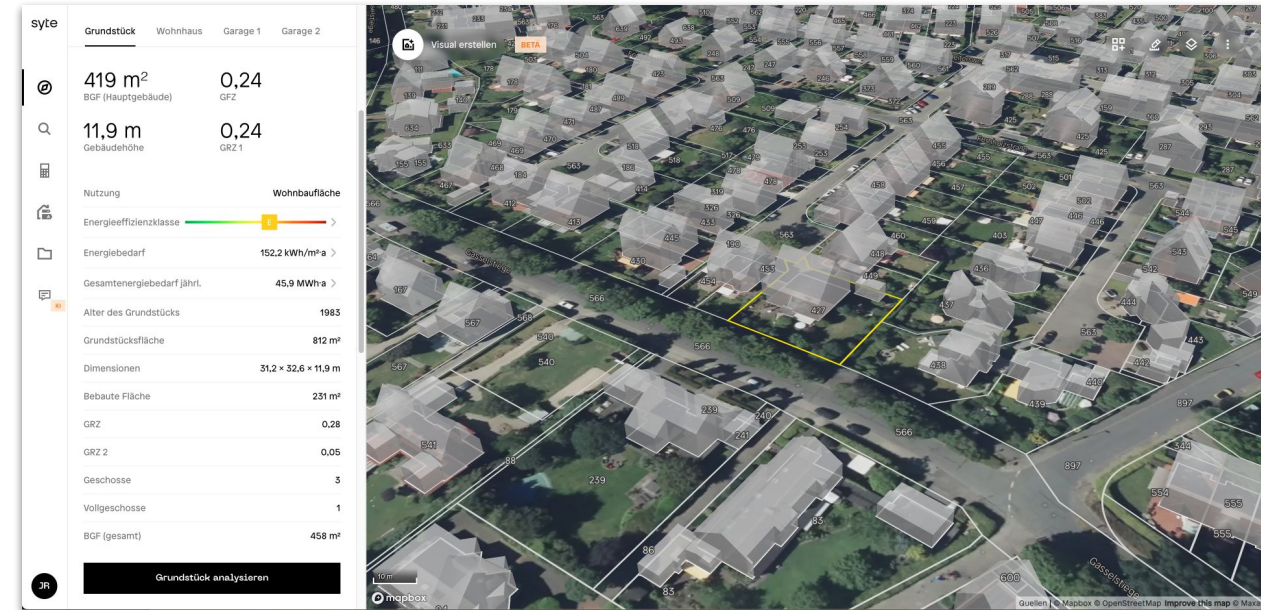
14. November 2025

Hybride Ansätze in der Geoinformation: Wie KI und Geometrie gemeinsam die Qualität von Gebäudedaten steigern

Dr. Julian Rasch - R&D Team Lead @ syte

Unser Ziel: Der Digitale Zwilling als Datenfundament

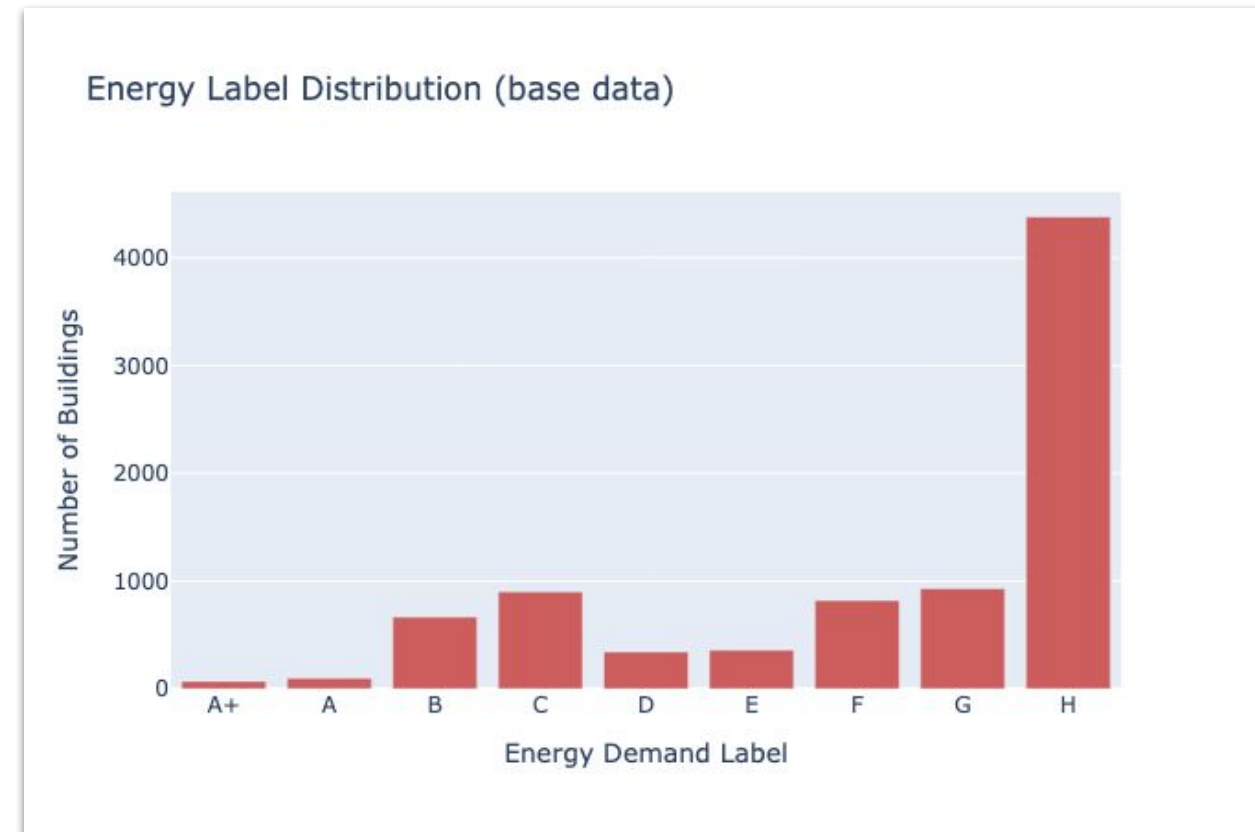
- Die syte GmbH erstellt einen Digitalen Zwilling Deutschlands.
- Datenbasis:** Methodische Fusion hunderter Datenquellen (ALKIS, Liegenschaftskataster, CityGML, Nexiga, Statistische Ämter, ...).
- Parameter:** LoD2-Geometrien, Flurstücke, Baualter, Stockwerke, Nutzung, etc.
- Zielsetzung:** Darauf aufbauende **Modellierungen** (z.B. Energiebedarf, Solarpotenzial, Geschossflächen).



Herausforderung: Datenqualität & Modellvalidität

- Die Realität: Basisdaten sind oft veraltet, unvollständig oder fehlerhaft.
- **Problemstellung:** Fehlerhafte Eingabedaten **propagieren** durch die Modellkette und beeinträchtigen das Ergebnis. **"Garbage in, Garbage out."**

Beispiel: (Geschätzte) Energielabel-Verteilung der Stadt Pinneberg





Problem-Vertiefung: Statische Daten vs. Physischer Zustand

- **Beispiel Stockwerke:** Ein so trivialer Parameter fehlt in nahezu jeder Datenbank.
- **Beispiel Baualter:** Ein Gebäude von 1960 (Basisdatum) ist nicht zwangsläufig Energieeffizienzklasse G.
- **Der kritischste fehlende Parameter:** Der **Renovierungsstand** (Dach, Fassade, Fenster) ist in fast keiner Datenbank verfügbar.
- Die statischen Basisdaten **reflektieren** nicht den *tatsächlichen, physischen Zustand*.

Künstliche Intelligenz für die automatische Stockwerkerkennung

Daten & Standards / Leipzig / Technologie & Innovationen


Im Anwendungsfall „Stockwerkerkennung“ wird versucht, eine Datenlücke innerhalb der Stadt zu füllen: die Anzahl der Stockwerke von Gebäuden. Vor allem für Altbestand fehlt diese Information und eine manuelle Erfassung für alle Gebäude der Stadt wäre sehr langwierig und zeitaufwendig.

<https://www.connectedurbantwins.de/loesungen/kuenstliche-intelligenz-fuer-die-automatische-stockwerkerkennung/>

Deep Learning-Based WWR and Floor Count Extraction from Façade Images to Improve UBE

Ayca Duran, Panagiotis Karapiperis, Christoph Waibel, Arno Schlueter

Paper – CISBAT 2025



<https://github.com/ycdrn/deepL4ubem>

Lösungsansatz: Extraktion von Gebäude-Attributen aus Bilddaten

- Wir nutzen aktuelle Bilddaten (Orthophotos, Schrägbilder), um die fehlenden Attribute zu schätzen.
- **Aber: Das ist methodisch nicht trivial.**
- **Herausforderungen:**
 1. **Verfügbarkeit:** Bildquellen sehr fragmentiert und unvollständig.
 2. **Pixel-genaue Georeferenzierung:** Welches Pixel gehört zu welchem Haus?
 3. **Verdeckung (Occlusion):** Bäume, Nachbargebäude.
 4. **Blickwinkel:** Fassaden in Nadir-Bildern (Senkrechtaufnahmen) nur am Rand sichtbar.
 5. **Mangel an validen Trainingsdaten** ("Ground Truth").




Unsere Methodik: Die "Geometrie-informierte KI"

- **Der "KI-first"-Ansatz:** "KI als Black Box" (rein datengetrieben) → Auf riesige Datenmengen werfen. Scheitert u.a. an o.g. **geometrischen Constraints**.
- **Unser pragmatischer Ansatz:** "Geometrie zuerst, dann KI"
- Wir nutzen **deterministische, geometrische Verfahren** als **Validierungs- und Filter-Schicht**.
- **Synergie:** Geometrie löst die Lokalisierung & Validierung; KI **skaliert** die Klassifikation & Parameterschätzung.



Beispiel 1: Dach-Klassifikation (Geo-informiertes Training)

- **Ziel:** Renovierungsstand von Dächern aus Orthophotos klassifizieren.
- **Herausforderung:** Fehlende **Referenzdaten** ("Ground Truth").
- **Unser Workflow:**
 - **Schritt 1 (Geometrie): Pixel-genaue Maskierung** der Dächer über Gebäudefootprints (ALKIS). Die KI schaut nur auf die relevanten Pixel.
 - **Schritt 2 (Daten-Heuristik):** Nutzung von Baualter-Daten als '**Noisy Labels**' (**Weak Supervision**):
 - Baujahr > 1995 = Label "Neu" (hohe Konfidenz)
 - Baujahr < 1995 = Label "Alt" (niedrige Konfidenz, Rauschen von ca. 15-20% sanierten Dächern)




Beispiel 1: Inferenz aus den "False Positives"

- **Schritt 3 (Modellierung):** Wir trainieren ein CNN (EfficientNetB0) auf diesem "rauschenden" Datensatz, um "neu" vs. "alt" zu klassifizieren.
- **Der analytische Fokus:** Gezielte Untersuchung der "False Positives"!
- **Definition:** Ein Gebäude mit **Heuristik-Label "Alt"** (Baujahr < 1995), das vom CNN sicher als "Neu" klassifiziert wird.
- **Inferenz:** Dies sind mit hoher Wahrscheinlichkeit die **tatsächlich sanierten Dächer**.
- → **Generierung** eines neuen, wertvollen Parameters ("Dach saniert: Ja/Nein").



Beispiel 2: Fassaden-Analyse (Geometrische Vor-Validierung)

- **Ziel: Parameterschätzung** für Fassaden aus Schrägbildern (Stockwerke, Fenster, Zustand).
- **Herausforderung:** Verdeckung (Occlusion) durch Gebäude und Vegetation.
- **Workflow (Deterministische Vor-Analyse):**
 - **Schritt 1 (Lokalisierung):** Projektion des LoD2-Modells in das Schrägbild (Pinhole-Kamera). → Wir wissen exakt, welche Pixel zu welcher Fassade gehören.



Beispiel 2: Der "Geo-Filter" (Sichtbarkeitsanalyse)


Workflow (Fortsetzung):

- **Schritt 2 (Filter 1 - Gebäude-Occlusion):**
Erstellung einer Tiefenkarte (Z-Buffer / Abstand zur Kamera).
 - *Regel:* Ist ein anderes Gebäude-Polygon näher an der Kamera als die Ziel-Fassade?
→ **Pixel werden verworfen.**



Beispiel 2: Der "Geo-Filter" (Sichtbarkeitsanalyse)

- **Schritt 3 (Filter 2 - Vegetations-Occlusion):**
Semantische Segmentierung von Vegetation (Bäumen).
 - *Regel:* Verdeckt Vegetation die Fassaden-Pixel? → **Pixel werden verworfen.**





Beispiel 2: Validierte Pixel als KI-Input

- **Erst nach dieser geometrischen Validierung:**
Die verbleibenden, "sauberen" Fassaden-Pixel werden an ein KI-Modell (z.B. Vision-LLM) zur Analyse gegeben.
- **Ergebnis:**
 - **Robuste Korrektur** der Basisparameter (Anzahl Stockwerke, Fensterflächen).
 - Schätzung des Fassaden-Renovierungsstandes.
- **Ausblick:** Grundlage für die **Texturierung** von LoD3-Modellen.





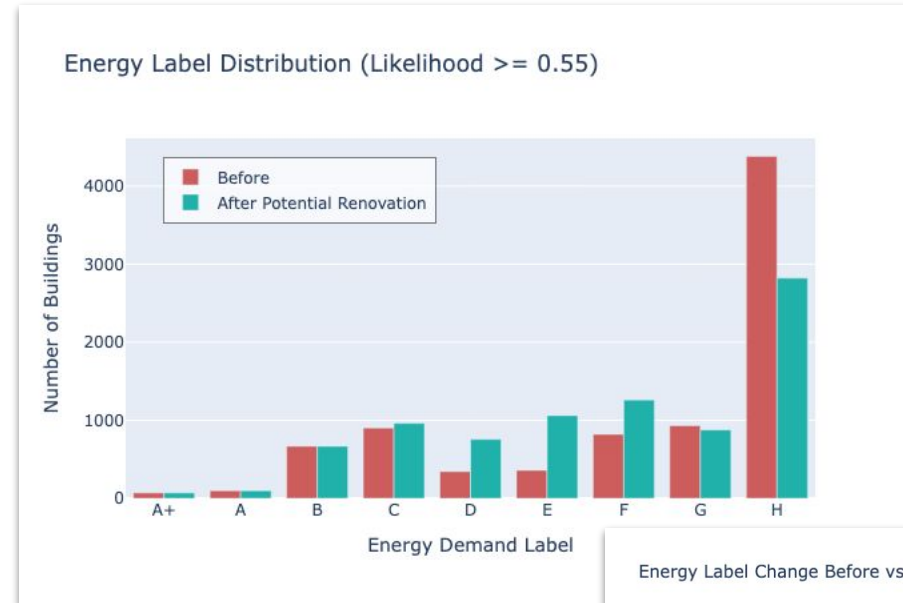
Ein paar inspirierende Bilder




Das Ergebnis: Vom "GIGO" zum "Quality Input"

- Neuberechnung der **Modell-Kaskaden** (z.B. Energieeffizienz) mit den **validierten Parametern** (Dachsanierung, Stockwerke, etc.).
- Die darauf aufbauenden **Ableitungen** werden präzise und verlässlich.

Beispiel: (Geschätzte) Energielabel-Verteilung der Stadt Pinneberg



Energy Label Change Before vs. After (Likelihood ≥ 0.55)





Fazit: Synergie als methodische Notwendigkeit

1. "GIGO" ist das Kernproblem heutiger Digitaler Zwillinge.
2. Naive KI-Ansätze scheitern an den **geometrischen Constraints** der Geoinformation (Verdeckung, Lokalisierung).
3. **Die Lösung ist eine pragmatische, hybride Methodik:**
 - **Geometrie** stellt die *richtigen Fragen* und **validiert den Input**.
 - **KI** liefert die *skalierten Antworten* (Inferenz) auf diese präzisen Fragen.
4. Das Ergebnis: Eine Qualitätssteigerung der Gebäudedaten.



Fragen & Diskussion

Vielen Dank!

Julian Rasch
R&D Team Lead @ syte GmbH
julian.rasch@syte.ms
www.syte.ms