

Klimatechnik-Betriebsoptimierung mittels maschinellem Lernen

Dr.-Ing. Thomas Oppelt

Wissenschaftlich-technischer Mitarbeiter

ILK Dresden



Berlin, 28./29. Januar 2021



Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

Klimatechnik-Betriebsoptimierung mittels maschinellem Lernen


Klimasysteme intelligent regeln – hoher Komfort bei niedrigem Energiebedarf

- Forschungsprojekt am ILK Dresden
- Gefördert durch BMWi im Programm Innokom
- Projektvorstellung
 - Motivation und Projektziel
 - Lösungsansatz
 - Prognosen und ML-Verfahren
 - Beispiel Anwesenheitsprognose
 - Weitere Bausteine

Motivation und Projektziel

- **Problem: Energieeffizienz** klimatechnischer Systeme im Betrieb häufig **geringer** als während Planung prognostiziert
- **Ursache** u.a.: komplexe Systeme werden häufig **nicht optimal betrieben**:
 - Regelparameter (z.B. Sollwerte) nicht optimal
 - Unbemerkte Ausfälle von Sensoren und Aktoren
 - Keine vorausschauende Regelung
 - ...
- → **Projektziel**: Entwicklung eines **Betriebsoptimierungs-Tools** für klimatechnische Systeme
 - Verwendung von Methoden des **maschinellen Lernens** (ML)
 - Nutzung von Daten aus dem **digitalen Gebäudemodell** (BIM)
 - **Optimierungsziel**: hohe Energieeffizienz bei gleichzeitig hoher Nutzerzufriedenheit
 - **Einsparung** von Betriebskosten, Energie und Kohlendioxidemissionen durch Effizienzsteigerung
 - **autoadaptive** Reaktion auf sich ändernde Bedingungen

Lösungsansatz



- Abbildung des **thermisch-energetischen Verhaltens** des realen Systems im Maschinen-Lern-System
- Anlernen mittels **BIM- und Messdaten** sowie anhand eines **digitalen Zwillings** des Realsystems
- Nutzung von ML-Methoden zur **Prognose von Lasten**
- **Fehlerdetektion**
- Integration verfügbarer Tools zur effizienten **Raumströmungssimulation**
- **Co-Validierung** von Optimierungstool, experimentellen Untersuchungen und digitalem Zwilling

Prognosen und ML-Verfahren

Erforderliche Prognosen

- Anwesenheit/Belegung
- Innere thermische Lasten (z.B. Geräte)
- Wetter
- Wärmeeintrag durch die Raum-/Gebäudehülle
- Entwicklung der Raumtemperatur
- Verhalten der RLT-Anlage
- → Welche Verfahren sind geeignet, welche Einflussparameter (Features) sind für ausreichend präzise Prognosen nötig?

Verfügbare ML-Verfahren (Auswahl)

Klassifizierung

- k-nearest neighbor
- Support vector machine (SVM)
- Decision tree
- Random forest
- ...
- KNN

Regression

- Lineare Regression
- Support vector machine regression (SVR)
- Random forest
- ...
- KNN

Beispiel: Anwesenheits-/Belegungsprognose

Warum prognostizieren?

- Ankunft der ersten Nutzer bestimmt den Zeitpunkt, zu dem die **Solltemperatur** im Raum **erreicht** sein muss
 - Je nach Speichervermögen des Raums kann **vor Weggang** der letzten Nutzer bereits die Heizung oder Kühlung **reduziert** werden
 - Anwesenheit von Personen = **Wärmequelle**
 - Personen nutzen Geräte → innere Wärmequellen
- Anwesenheits-/Belegungsprognose nimmt **Schlüsselstellung** für Betriebsoptimierung ein


Welche Einflussparameter (Features) können relevant sein (Auswahl)?

- Monat
 - Arbeitstag/Nicht-Arbeitstag
 - Wochentag
 - Uhrzeit
 - Brückentag ja/nein
 - Schulferien ja/nein
 - Belegung aktuell/vorher (Vorgängerwert)
- So viele Features wie nötig verwenden, aber gleichzeitig das Prognosemodell möglichst einfach halten

Anwesenheits-/Belegungsprognose: Ergebnisse

Beispiel: Großraumbüro mit 20 Mitarbeitern,
Gleitzeit


- Prognose der Belegung im 15-min-Intervall
- Klassifizierung in 11 Klassen (0 Anwesende, 1 – 2 Anwesende, 3 – 4 usw.)
- Diagramm: Beispieltag, max. 18 Personen anwesend → Klasse 9
- Prognose mit Random Forest
 - Variante 6: Features Monat, Wochentag, Zeit, arbeitsfrei, Brückentag, Schulferien, Vorgängerwert
 - Variante 8: gleiche Features bis auf Vorgängerwert



Anwesenheits-/Belegungsprognose: Ergebnisse

Treffergenauigkeit für ein Jahr


in Abhängigkeit von berücksichtigten Features



Verwendete Features: 1: nur Vorgängerwert;
3: Vorgängerwert, Zeit, arbeitsfrei;
5: wie 2 + Schulferien, Brückentag; 9: nur Zeit (ohne Vorgängerwert); 13: alles außer Vorgängerwert


Verfahren: Random forest

in Abhängigkeit vom Klassifizierungsverfahren



Verwendete Features: Vorgängerwert, Zeit, arbeitsfrei

Ausblick: weitere Bausteine



Mehr Informationen: www.ilkdresden.de