

Ableiten repräsentativer Betriebsperioden eines Industriebetriebs aus dem Papier- und Zellstoffsektor

(5) Dekarbonisierung: Industriegesektor

Sophie KNÖTTNER¹⁽¹⁾, Jan KURZIDIM⁽¹⁾, Simon DREYMANN²⁽¹⁾, Bernd WINDHOLZ⁽¹⁾

⁽¹⁾AIT Austrian Institute of Technology, Center for Energy

Motivation und zentrale Fragestellung

Rechenzeiten von gemischt-ganzzahligen linearen Optimierungsproblemen steigen mit der Anzahl ganzzahliger Entscheidungsvariablen [1]. Insbesondere bei Design-Fragestellungen beispielsweise zur Dekarbonisierung der Energieversorgung sind mehrfache Berechnungen notwendig zur Berücksichtigung verschiedener Entwicklungspfade. Beides motiviert, Rechenzeiten von Solvern kurz zu halten, beispielsweise durch:

- Effiziente Solver [2]
- Kompakte und enge Formulierung, z.B. [3]
- Lineare statt ganzzahliger Variablen
- Einsatz repräsentativer Perioden, z.B. [4]

Am Use-Case der Design-Optimierung von Energieversorgungsanlagen einer Papierfabrik waren übliche Ansätze zum Ableiten repräsentativer Perioden limitiert. Anhand dieses Use-Cases wird in diesem Beitrag ein Ansatz vorgestellt, der Domänenwissen erfolgreich mit Clustering-Methoden kombiniert. Abschließend werden Verbesserungsmöglichkeiten diskutiert, die weitere Anwendungen ergeben haben.

Methodische Vorgangsweise

Abbildung 1 zeigt die Arbeitsschritte des entwickelten Ansatzes.




Abbildung 1: Ablaufschema

Schritt 1: Eingehende Datenexploration sowie Bereinigungen zur Qualitätsherstellung. Behandelt werden verschiedene Datenformate, Zeitzonen und -raster, physikalische Einheiten, Ausreißer sowie fehlende Werte. Eine beispielhafte Herausforderung ist die Bestimmung von Ausreißern im Strompreis 2021, die nicht durch einfache statistische Methoden möglich ist.

Schritt 2: Zusammenführung der aufbereiteten Daten und grafische Analyse (Histogramme, Korrelationsdiagramme, Zeitreihendarstellung) mit unterschiedlichen Aggregationsebenen. Basierend darauf: Untersuchung der Menge (Zeitraum, Fehlwerte), Struktur (Einheiten, Redundanzen), Größenrelevanz (Mittelwert, Ausschläge) und Periodizität.

Schritt 3: Auswahl repräsentativer Zeiträume und zweistufige Gruppenbildung für Zeitreihen basierend auf Schritt 2 sowie Domänenwissen. Beispielhafte Gruppen-Abgrenzungen für Stufe 1: Systemgrenzen, Einheiten, Relevanz (z.B. Wärmeleistungszeitreihen). In Stufe 2 zusätzlich Zusammenfassung ausgewählter Zeitreihen (z.B. bei geringem Mittelwert) innerhalb der Gruppen durch Summation.

Schritt 4: Anwendung etablierter Clustering-Techniken, z.B. auf 24-Stunden-Teilintervalle, mit Stundenwerten als Features. Analysiert werden u.a. verschiedene Cluster-Anzahlen und Metriken

¹ Jungautorin, Giefinggasse 2, 1210 Wien, +43 664 88904337, sophie.knoettner@ait.ac.at

² Jungautor

(z.B. Mittelwert, Medoid) zur zuverlässigen Abbildung relevanter Zeitreihen-Eigenschaften. Auf jede Gruppe aus Schritt 3 wird ein separates Clustering angewendet.

Schritt 5: Kombination der separaten Clusterings durch Abzählen des gemeinsamen Auftretens von Cluster-Labels (z.B. Tag 1: Label 1 aus Clustering 1 - Label 3 Clustering 2 - Label 4 Clustering 3) und Definition der berücksichtigten repräsentativen Tage über Mindestanzahlen.

Ergebnisse und Schlussfolgerungen

In Schritt1 wurden folgende Zeitreihen als relevant identifiziert:

- Strombedarf
- Dampfbedarf
- Windgeschwindigkeiten
- Solare Einstrahlung
- Strompreise und spezifische Emissionen (historische Day-Ahead-Preis von 2019 sowie Ergebnisse eines europäischen Strommarktmodells unter Variation von Preisen für Erdgas und Emissionszertifikate)

Schritt 2 & 3: Bei der Gruppierung wurden zunächst zwei sowie final drei Zeitreihengruppen identifiziert. Die Zeitreihengruppen waren wie folgt:

- Starker jahreszeitlicher Einfluss, z.B. Fernwärme
- Leistungs-Zeitreihen ohne erkennbare Periodizität, z.B. Wärmeleistungsbedarf
- Preis-Zeitreihen ohne erkennbare Periodizität

Schritt 4: Für die Zeitreihengruppen wurden Clusterings mit zwei bis fünf Tagen durchgeführt. Ergebnisbasiert wurde je Gruppe ein Clustering für die finale Analyse ausgewählt und in die Kombination der Tage (Schritt 5) aufgenommen.

Für den Use-Case der Papierfabrik wurden folgende Erkenntnisse abgeleitet:

- Die Identifikation von Ausreißern der Strompreise 2021 zeigt, dass sich automatisierte Datenanalyse ohne Domänenwissen nicht für diesen Anwendungsfall eignet. Zu einem ähnlichen Schluss führt die Interpretation von Zwischenergebnissen des Clusterings.
- Das Ergebnis ermöglicht sowohl Optimierungsanwendern, beispielsweise für Dekarbonisierung was an einem Beispiel demonstriert wird, aber auch industriellen Betreibern ein hohes Maß an Nachvollziehbarkeit.
- Die Limitationen der Methode wurden für weitere Use-Cases aus diesem bzw. Nahrungsmittel-Sektor analysiert. Dadurch konnten Verbesserungspotentiale wie bspw. die Integration einer Frequenzanalyse, identifiziert werden.

Literatur

- [1] A. Richards and J. How, "Mixed-integer programming for control," Proceedings of the 2005, American Control Conference, 2005., 2005, pp. 2676-2683 vol. 4, doi: 10.1109/ACC.2005.1470372.
- [2] Koch, Thorsten; Achterberg, Tobias; Andersen, Erling; Bastert, Oliver; Berthold, Timo; Bixby, Robert E. et al. (2011): MIPLIB 2010. In: Math. Prog. Comp. 3 (2), S. 103–163. DOI: 10.1007/s12532-011-0025-9.
- [3] Morales-Espana; Latorre, Jesus M.; Ramos, Andres (2013): Tight and Compact MILP Formulation for the Thermal Unit Commitment Problem. In: IEEE Trans. Power Syst. 28 (4), S. 4897–4908. DOI: 10.1109/TPWRS.2013.2251373.
- [4] Poncelet, Kris; Hoschle, Hanspeter; Delarue, Erik; Virag, Ana; Drhaeseleer, William (2017): Selecting Representative Days for Capturing the Implications of Integrating Intermittent Renewables in Generation Expansion Planning Problems. In: IEEE Trans. Power Syst. 32 (3), S. 1936–1948. DOI: 10.1109/TPWRS.2016.2596803.