

Series Decomposition and Attention based Feature Extraction for Energy Time Series Prediction (Master thesis)

Autor: Xing Li
Erstprüfer: Prof. Dr.-Ing. Dirk Müller
Betreuung: Jan Priesmann, M. Sc.; Lars Nolting, M. Sc.; Thomas Storek, M. Sc.

Kurzfassung

In dieser Arbeit konzentrieren wir uns hauptsächlich auf die kurzfristige mehrstufige Vorhersage von Energiezeitreihen. Praktische Energiezeitreihen wie Last-, Photovoltaik- und Windreihen sind eine Mischung aus mehreren und dynamischen Mustern. Es gibt zwei allgemeine Ansätze zur Modellierung komplexer Reihen. Das erste besteht darin, Hybridmodelle zu entwerfen, die auf Zerlegung, Zustandsraummodellen und deep learning Modellen basieren. Zerlegungsmethoden zerlegen komplexe Reihen in mehrere, aber einfache Muster und arbeiten als Vorverarbeitungskomponente, um verständliche Merkmale zu extrahieren. Dann werden Muster mit einem oder mehreren einfachen Vorhersagemodellen vorhergesagt. Die zweite besteht darin, sorgfältig maßgeschneiderte und leistungsstarke Modelle zu entwerfen, die ohne andere Vorverarbeitungskomponenten genaue Vorhersagen liefern können. Wir arbeiten an diesen beiden vielversprechenden, aber entgegengesetzten Richtungen.

Obwohl viele Hybridmodelle vorgeschlagen werden, sind sie für praktische Anwendungen schwer zu vergleichen und auszuwählen. Daher schlagen wir zunächst einen allgemeinen und flexiblen Rahmen vor, um die Vorteile von Zerlegungs- und deep learning Modellen zu nutzen. Es passt zu den meisten Hybridmodellen und kann einfach zum Modellvergleich und zur Modellauswahl implementiert werden. Das Framework ist auch erweiterbar und Komponenten davon können nacheinander oder parallel zusammengebaut werden. Darüber hinaus können dank der Flexibilität von deep learning Modellen mehrere aus dem Framework erstellte Modelle parallel auf dieselbe Eingabe angewendet werden.

Einige Zeitreihen haben mehrere Saisonalitäten, was nicht nur die Vorhersagbarkeit, sondern auch die Vorhersageschwierigkeiten erhöht. Wir verlassen uns nicht nur auf die Zerlegung, um Interpretierbarkeit und Fähigkeit zu erlangen, sondern schlagen auch ein deep learning Modell vor, das als Encoder-Decoder mit mehreren wiederkehrenden Sprüngen und zeitlicher Attention bezeichnet wird. Es kann multivariate endogene und exogene Reihen mit Faltungsschichten verarbeiten, die kurzfristige Merkmale und Antriebsreihen erfassen. Auf wiederkehrenden überspringenden Schichten basierender Encoder und auf zeitlicher Attention basierender Decoder können saisonale Muster extrahieren und interpretierbare Eingabe-Ausgabe-Gewichte erzeugen. Ein Encoder-Decoder mit der eindeutigen Periode als Sprungschritt wird verwendet, um die entsprechende Saisonalität zu identifizieren, und mehrere und parallele Encoder-Decoder können somit mehrere Saisonalitäten gleichzeitig modellieren. Numerische Ergebnisse für die univariaten und multivariaten Lastdatensätze zeigen in einigen Fällen eine Verbesserung der Robustheit (5,6 %) und Genauigkeit (8,6 %) gegenüber Basismodellen.

Abstract

In this thesis, we mainly focus on short-term multi-step energy time series trajectory prediction. Practical energy time series, such as load, photovoltaic and wind series are a mixture of multiple and dynamic patterns. There are two general approaches to model complex series. The first is to design hybrid models based on decomposition, state-space models and deep learning models. Decomposition methods decompose complex series into multiple but simple subseries and work as a pre-processing component to extract understandable features. Then subseries are predicted with one or multiple simple prediction model(s). The second is to carefully design tailor-made and powerful models that can provide accurate predictions without other pre-processing components. We work on these two promising but opposite directions.

Although many hybrid models are proposed, they are hard to be compared and selected for practical applications. Thus we first propose a general and flexible framework to utilize the advantages of decomposition and deep learning models. It fits most hybrid models and can be easily implemented for model comparison and selection. The framework is also extendable and components of it can be assembled sequentially or in parallel. Additionally, multiple models constructed from the framework can be applied in parallel to the same input, thanks to the flexibility of deep learning models.

Some series have multiple seasonality, increasing not only the predictability but also the prediction difficulty. Apart from relying on decomposition to gain interpretability and capability, we also propose an deep learning model called multiple recurrent-skip and temporal attention based encoder-decoder. It can process multivariate endogenous and exogenous series with convolutional layers capturing short-term features and driving series. Recurrent-skip layers based encoder and temporal attention based decoder can extract seasonal patterns and generate interpretable input-output weights. An encoder-decoder with the unique period as the skip step is used to identify the corresponding seasonality, and multiple and parallel encoder-decoders can thus model multiple seasonality simultaneously. Numerical results on the univariate and multivariate load datasets show the improvement of robustness (5.6%) and accuracy (8.6%) than baseline models in some cases.