

Optimaal plannen van batterijsystemen op basis van voorspeld verbruik onder dynamische elektriciteitsprijzen en het capaciteitstarief

Cyl Rouseré

Studentennummer: 01912876

Promotor: prof. dr. ir. Jan Desmet

Begeleider: Toon Vanhove

Masterproef ingediend tot het behalen van de academische graad van
Master of Science in de industriële wetenschappen: elektrotechniek - automatisering

Academiejaar 2024-2025

Voorwoord

Dankwoord

Graag wil ik mijn begeleider, Toon Vanhove, bedanken voor de waardevolle begeleiding, inhoudelijke feedback en ondersteuning gedurende dit traject. Zijn kritische blik en advies waren van grote betekenis voor het tot stand komen van deze masterproef.

Daarnaast ben ik mijn familie en vrienden dankbaar voor hun morele steun, aanmoediging en het creëren van de ruimte en rust die ik nodig had om mij ten volle op dit werk te concentreren.

Toelating tot bruikleen

De auteur(s) geeft (geven) de toelating om deze masterproef voor consultatie beschikbaar te stellen en delen van de masterproef te kopiëren voor persoonlijk gebruik. Elk ander gebruik valt onder de bepalingen van het auteursrecht, in het bijzonder met betrekking tot de verplichting de bron uitdrukkelijk te vermelden bij het aanhalen van resultaten uit deze masterproef.”

22/05/2025

Toelichting in verband met het master-proefwerk

Deze masterproef vormt een onderdeel van een examen. Eventuele opmerkingen die door de beoordelingscommissie tijdens de mondelinge uiteenzetting van de masterproef werden geformuleerd, werden niet verwerkt in deze tekst.

Abstract

Deze masterproef onderzoekt hoe batterijsystemen optimaal kunnen worden aangestuurd in een context van dynamische elektriciteitsprijzen en het Belgische capaciteits-tarief. De focus ligt op industriële verbruikers, waarbij gestreefd wordt naar het minimaliseren van de totale energiekost.

Een nieuw Rolling Horizon Linear Programming (RHLP)-algoritme werd ontwikkeld en vergeleken met een eenvoudig heuristisch basisalgoritme. Het RHLP-algoritme gebruikt PV-opbrengst, dynamische prijzen en verbruiksvoorspellingen op basis van Extreme Gradient Boosting (XGBoost) om de laad- en ontlaadbeslissingen te optimaliseren over een tijdshorizon van 48 uur. Deze horizon schuift mee met de tijd (rolling horizon), waarbij de optimalisatie om de 15 minuten wordt herhaald. De PV-opbrengst werd in de standaardconfiguratie benaderd via werkelijke historische waarden.

De algoritmes werden geëvalueerd aan de hand van uitgebreide simulaties op reële verbruiksprofielen en historische Belpex-prijzdata. De resultaten tonen aan dat onder de juiste omstandigheden het RHLP-algoritme tot 20% kostenbesparing kan realiseren in vergelijking met het basisalgoritme.

Nacht- en weekendverbruik bleek een bepalende factor in de behaalde optimalisatie-winst, wat duidt op een duidelijke invloed van het verbruiksprofiel op het prestatiepotentieel van het algoritme. Daarnaast bleken ook parameters zoals batterijcapaciteit en prijsschommelingen op de markt van doorslaggevend belang voor de gerealiseerde resultaten.

Dit onderzoek toont aan dat batterijsturing op basis van verbruiksvoorspellingen via lineaire optimalisatie kostenbesparingen kan opleveren.

Trefwoorden: batterijopslag, Photovoltaïsch – zonnepaneelinstallatie (PV), dynamische prijzen, Linear Programming – lineaire programmering (LP), verbruiksvoorspelling, kostenoptimalisatie.

Cost Optimization of Battery Dispatch under Dynamic Electricity Prices and Capacity Tariff

Cyl Rousere

Department of Electrical Engineering - Automation
Ghent University
Ghent, Belgium
cyl.rousere@ugent.be

Abstract—This thesis investigates how battery storage systems can be optimally controlled for industrial consumers in Flanders, where dynamic electricity pricing and the capacity tariff are becoming increasingly influential. A Rolling Horizon Linear Programming (RHLP) algorithm was developed and benchmarked against a static rule-based baseline algorithm. Through extensive simulations, the study evaluates the RHLP algorithm using real historical data on consumption, PV generation, and Belpex market prices. Results show that the algorithm achieves up to 20% cost reduction. The method effectively exploits price signals and consumption flexibility, especially under volatile market conditions.

Index Terms—battery storage, linear programming, dynamic pricing, XGBoost, demand forecasting, energy optimization

I. INTRODUCTION

The Flemish energy system is undergoing a profound transition, driven by the rollout of digital meters, the rise of renewable generation, the growing adoption of electric vehicles and heat pumps, and the overall electrification of industrial processes. In addition to a significant increase in total energy consumption, these developments result in a more decentralized and less predictable electricity landscape [1]. Two key concepts for end-users are **peak shaving**—the reduction of consumption peaks to minimize capacity charges—and **self-consumption**—the local use of solar PV energy to reduce reliance on grid imports.

These practices can be supported by battery storage systems. Traditionally, batteries were managed through simple rule-based logic. However, the emergence of **dynamic electricity contracts**, where prices currently vary on an hourly basis based on the Belpex day-ahead market, opens new opportunities for predictive and price-aware control strategies [2]. A shift to quarter-hourly pricing is expected in the near future, which may further increase the granularity and potential of such dynamic contracts.

This research introduces a novel **Rolling Horizon Linear Programming (RHLP)** algorithm that combines forecasted electricity demand (via XGBoost) and solar production to optimize battery usage over a 48-hour sliding window. The core research question is:

Can a forecast-driven optimization algorithm (RHLP) outperform a simple rule-based baseline in terms of total energy cost under dynamic pricing and the capacity tariff?

Simulations compare both strategies under realistic conditions, accounting for different consumption profiles, battery sizes, and market regimes. Additional questions explored include: How does prediction accuracy affect RHLP performance? Which users benefit most? And how sensitive is the system to price volatility?

II. FORECASTING APPROACH

In order to effectively dispatch a battery, future opportunities to charge or discharge the battery need to be weighed against current opportunities. Assessing these opportunities requires reliable forecasts of future system behavior. This section elaborates on the methods and rationale behind the forecasting models used, with particular focus on load forecasting via XGBoost.

A. Price Availability and Forecasting Horizon

For consumers under dynamic electricity contracts, day-ahead market prices are published at 13:00 on the day before delivery, after closure of the Belpex day-ahead auction. From that moment, all suppliers and consumers know the prices for the 24 hours of the following day, plus the remaining hours of the current day (from 13:00 to 24:00). This implies that the known price horizon ranges from a minimum of 11 hours (just before publication) to a maximum of 35 hours (just after publication), depending on the time of day.

In this study, we assume perfect knowledge of prices up to 48 hours in advance. This assumption matches the rolling optimization horizon of the RHLP algorithm, ensuring consistency between price and consumption forecasts. While idealized, this assumption allows for an upper-bound assessment of the optimization strategy's performance.

In real-world deployment, price uncertainty beyond the first day could be addressed in two ways: (i) using true day-ahead prices for the known portion and statistical predictions for the unknown remainder, or (ii) shortening the optimization horizon to match the certainty window.

B. PV Output Forecasting

Since numerous robust methods exist for forecasting PV generation with high accuracy (MAPE 2–7% according to [3]), this work assumes that PV output is perfectly known. A practical implementation could rely on external APIs providing

solar forecasts based on irradiance, temperature, and cloud coverage.

C. Model Selection for Load Forecasting

Multiple techniques were evaluated for electricity demand forecasting, grouped into three categories:

- **Statistical models** (e.g., ARIMA, SARIMA) are interpretable and effective for stationary time series, but generally underperform when dealing with highly non-linear or irregular demand.
- **Machine learning models** (e.g., Random Forest, SVR) can handle structured input well and are robust to outliers. However, some—such as SVR—scale poorly with data volume.
- **Deep learning models** (e.g., LSTM) are capable of capturing complex temporal dependencies, but require large datasets, long training times, and are typically less interpretable.

After comparative testing, **XGBoost** was selected as the preferred model due to its strong performance on structured industrial datasets, fast training, and high interpretability. The details of its implementation are outlined below.

D. XGBoost Implementation and Training

XGBoost (Extreme Gradient Boosting) is an ensemble learning algorithm that combines the predictions of many shallow decision trees using gradient boosting. Introduced by Chen and Guestrin [4], it is widely used for regression and classification tasks due to its efficiency and scalability.

In this work, the model was trained on two years of historical 15-minute consumption data, generating forecasts for a full test year. Input features included:

- time-of-day and weekday indicators,
- Fourier-transformed variables to capture daily and weekly load cycles,
- a manually coded `workday` flag based on public holidays and weekend profiles.

These features were selected to reflect typical industrial consumption patterns such as peak/off-peak variation and reduced weekend activity.

The model was trained using the hyperparameters shown in Table I, optimized to minimize root mean squared error (RMSE):

TABLE I: Hyperparameters used for XGBoost load forecasting

Parameter	Value
<code>n_estimators</code>	10000
<code>max_depth</code>	8
<code>learning_rate</code>	0.002
<code>subsample</code>	0.8
<code>colsample_bytree</code>	0.8
<code>objective</code>	<code>reg:squarederror</code>
<code>eval_metric</code>	<code>rmse</code>




Fig. 1: Actual vs predicted load using XGBoost

E. Evaluation Metrics

Forecast accuracy was evaluated using standard regression metrics: RMSE, MAE, R^2 , MAPE, and normalized RMSE. In addition, peak detection performance was measured using classification metrics. Peaks were defined as load values above the 80th percentile. Results for User 15 are summarized in Table II.

TABLE II: Forecasting performance for User 15 (XGBoost)

Metric	Value
RMSE	7.90
MAE	4.90
R^2	0.636
MAPE	50.4%
NRMSE (vs. mean)	0.630
Precision (peak)	0.765
Recall (peak)	0.533
F1-score (peak)	0.629

F. Feature Importance

The most influential features were the manually defined `workday` flag and the Fourier components capturing daily and weekly cycles. These input variables are visualized in Figure 2.




Fig. 2: Feature importance (XGBoost model for User 15)

G. Conclusion on Forecasting

XGBoost proved to be a highly suitable choice for load forecasting in industrial contexts. While deep learning methods

may offer improvements in some cases, the model's speed, stability, and ability to detect consumption peaks with reasonable accuracy made it ideal for integration into the RHLP optimization algorithm.

Due to the nature of the Flemish capacity tariff—where only the highest monthly peak determines the cost component—forecasting requires consistent accuracy and the ability to detect every significant peak. Missing a single high load event can disproportionately impact the final cost. Therefore, the most relevant way to evaluate forecast performance is its effect on the RHLP algorithm's outcomes. This is assessed in Section VI.

III. BASELINE ALGORITHM

The baseline algorithm used in this study serves as a heuristic benchmark for battery dispatch. It operates through a static, sequential logic that does not rely on forecasting or price information. Its purpose is to mimic the kind of rule-based control typically found in conventional battery management systems. The control is divided into two separate stages: **Self-Consumption Optimization (ZC)** and **Peak Shaving (PS)**. These stages operate independently and sequentially, with each assigned to a fixed, pre-allocated portion of the battery.

A. Battery Partitioning

At the start of the simulation period, the available battery capacity is split into two virtual segments: one for self-consumption and one for peak shaving. This partitioning is fixed throughout the year. For example, if 40% of the battery is reserved for PS, then that segment is unavailable for ZC purposes—even if no peaks occur. This rigid allocation reflects the lack of adaptive coordination within the baseline logic.

B. Stage 1: Self-Consumption Optimization (ZC)

In the first stage, the battery prioritizes maximizing local PV self-consumption. Every 15 minutes, it compares the instantaneous load to the PV generation and charges or discharges accordingly—limited by battery constraints and without consideration of electricity prices.

C. Stage 2: Peak Shaving (PS)

The second stage addresses short-term peak reduction. If the net load after ZC exceeds a fixed threshold (the *cutoff*), the battery discharges to reduce the peak. If it remains below, the system charges opportunistically to prepare for possible future peaks. This logic is purely reactive and does not involve forecasting.

D. Summary and Evaluation

The baseline algorithm is simple and computationally efficient. Its two-stage structure enables:

- Enhanced self-consumption of PV energy through reactive buffering,
- Reduction of grid import peaks via reactive shaving above a fixed threshold.

However, its major limitations include:

- No dynamic coordination between ZC and PS segments,
- No adaptation based on future price or consumption trends,
- Risk of battery under-utilization if one segment remains unused.

Despite these constraints, the baseline offers a reproducible, interpretable reference point against which more advanced strategies—such as the RHLP algorithm—can be quantitatively evaluated.

IV. ROLLING HORIZON LINEAR PROGRAMMING (RHLP) ALGORITHM

The RHLP algorithm is designed to schedule the battery in a forward-looking manner by solving a cost-minimization problem every 15 minutes. It anticipates electricity prices, PV generation and demand over the next 48 hours and makes optimal decisions accordingly. At every quarter-hour, the following steps are performed:

- 1) The system collects forecasts for electricity demand and solar production for the next two days. Demand is predicted using XGBoost; PV output is assumed to follow recent actual production patterns.
- 2) Dynamic electricity prices are obtained from the Belpex day-ahead market and integrated with taxes, levies, and distribution tariffs.
- 3) Based on this forecast information, the algorithm constructs a detailed plan for the battery: when to charge, discharge, or remain idle. These decisions are based on minimizing the total net cost over the next 48 hours. This cost includes electricity import from the grid, potential earnings from exporting surplus power, and penalties for exceeding a predefined consumption peak.
- 4) Only the action corresponding to the first 15-minute step of the plan is actually executed. After that, the time window shifts one step forward, and the entire process repeats with updated input data. While it would be computationally more efficient to execute the entire schedule at once, doing so would rely on increasingly uncertain forecasts. By re-optimizing every 15 minutes, we ensure that each executed decision is based on the most recent data and retains a full 48-hour forecast horizon ahead.

Internally, the algorithm considers all constraints of the system, such as maximum charging and discharging power, the limits of the state of charge (SoC), and the technical capacity of the battery. It also tracks the flow of energy from the PV installation, grid import/export, and battery storage. By simulating the energy balance at each time step and ensuring the physical integrity of the system, the algorithm identifies the cheapest path of operation.

An important structural advantage of RHLP over traditional approaches is that it does **not require a predefined partitioning of the battery capacity for different objectives** such as peak shaving or self-consumption. In contrast to rule-based algorithms that allocate a fixed percentage of the battery

to each function (which can lead to inefficient utilization), the RHL algorithm dynamically determines at each moment how the full battery capacity should be used. Although this behavior is not explicitly coded as a rule, the optimization engine naturally assigns the appropriate portion of the battery to the most beneficial task based on current forecasts. This allows the system to allocate 100% of the storage to self-consumption during sunny hours, and to reserve the battery for peak shaving during expected consumption spikes—thus ensuring **maximum flexibility and efficiency**.

In summary, RHL enables industrial users to reduce their energy bills by planning battery behavior in advance, based on forecasts and price signals. It offers significantly better performance than rule-based systems, especially in dynamic market conditions and for users with flexible consumption profiles.

V. PARAMETER SELECTION AND SIMULATION SETUP

To ensure realistic simulation results, the following key parameters must be defined carefully: the size of the photovoltaic (PV) installation, the battery capacity, and the peak shaving threshold. These parameters were not directly available in the dataset and were therefore derived using a combination of empirical data analysis, rule-based assumptions, and literature guidance.

A. Simulation Data and Temporal Scope

The simulation uses consumption data from 2014–2016 for each industrial user. Data from 2014 and 2015 were used to train the XGBoost forecasting model, while the year 2016 served as the evaluation and simulation period.

B. PV System Sizing

The PV generation profile is normalized and then scaled such that its annual output matches the average annual electricity consumption (based on 2014–2015). This corresponds to a 1:1 sizing strategy, where the installed PV capacity in kWp approximately equals the battery capacity in kWh. This configuration maximizes local self-consumption and avoids excess grid injection, aligning with recommendations for self-consumption optimization in systems without feed-in capabilities [5].

Moreover, a 50/50 east-west orientation of panels was simulated by averaging the production profiles for each orientation. East–west orientation is a common configuration in industrial rooftop PV installations due to limited roof space and its favorable ground coverage ratio. This layout allows for denser panel placement and provides a more balanced energy production throughout the day, which aligns better with typical industrial consumption patterns [6]. In this study, panels are assumed to be installed under a tilt angle of 10°.

C. Battery Capacity

The battery storage size is determined based on the 1:1 ratio with PV capacity. The usable battery capacity is adjusted for the Depth of Discharge (DoD):

- A 100 kWp PV system implies 100 kWh usable storage.
- With a DoD of 80%, the nominal capacity would be 125 kWh.

This relationship ensures the battery can buffer typical daily production and shift load effectively, facilitating peak shaving and self-consumption.

D. Peak Shaving Threshold Determination

To determine a suitable threshold for peak shaving, the Load Duration Curve (LDC) of each user was analyzed. Specifically, the point of inflection—identified via the second derivative of the LDC—was used as the cutoff. This marks the transition from high-intensity peaks to more consistent base load, providing a stable basis for peak control. This method is reproducible, computationally efficient, and grounded in prior research [7].

E. Contract Type

Two types of electricity contracts were used in simulations:

- **Variable Contract:** Used in combination with the baseline algorithm. Prices vary over longer intervals (monthly/quarterly) and are based on average Belpex indices or futures. This contract reflects the assumption that an industrial player who does not actively respond to dynamic price signals will also not opt for a dynamic contract structure.
- **Dynamic Contract:** Paired with the RHL algorithm. Prices are determined on the Belpex day-ahead market and provided on an hourly basis. In this study, historical Belpex prices are used to simulate dynamic price conditions and allow the algorithm to exploit price dynamics effectively.

VI. RESULTS AND EVALUATION

This section presents and analyzes the results of the simulations and experiments carried out to evaluate the performance of both the baseline and RHL algorithms under various realistic conditions. The focus lies not only on overall cost reduction but also on the influence of key parameters such as contract type, forecast accuracy, battery capacity, and user profile characteristics. Depending on the analysis, either a single representative user or a broader set of users is considered.

A. Realistic Contract Comparison

The baseline algorithm was tested under a variable tariff, reflecting conventional setups without price forecasts. The RHL algorithm, by contrast, was evaluated under a dynamic contract using realistic day-ahead price forecasts. Table III presents the detailed results for **User 12**, showing that the RHL algorithm achieves a cost reduction of **12.57%** compared to the baseline. This improvement is primarily due to lower energy costs, improved peak shaving, and reduced grid dependency.

TABLE III: Comparison of performance under realistic contract conditions (User 12)

Algorithm	Baseline Algorithm	RHLP Algorithm
Contract Type	Variable	Dynamic
Energy Cost (Import)	4679.10	3663.05
Injection Revenue	2628.03	2111.83
Total Grid Charges	4447.52	3644.15
Total Taxes and Levies	1480.18	1343.49
Imbalance Charges	0.00	0.00
Total Cost	7978.77	6980.17
Cost reduction [%]	–	12.57%

To assess the generalizability of these results, the same comparison was performed for five additional industrial users. Figure 3 illustrates the percentage cost savings achieved by the RHLP algorithm (with a dynamic tariff) compared to the baseline algorithm (with a variable tariff) for each user.




Fig. 3: Percentage cost reduction of RHLP vs. baseline algorithm per user (realistic contracts)

The results show that the RHLP algorithm yields a cost reduction for four out of six users, with savings ranging from **-7.05%** to **14.35%**. Two users (Users 7 & 15) experienced an increase in cost, likely due to unfavorable alignment between price signals and consumption peaks. On average, the RHLP algorithm achieved a **4.91%** cost reduction across all six users.

These findings confirm that predictive control under dynamic pricing yields modest but consistent financial benefits for most users compared to traditional rule-based logic under static tariff structures.

B. Impact of Forecast Accuracy

To assess the importance of forecast quality, the RHLP algorithm was tested using three types of input:

- 1) **Flat average load profile:** a profile where each time step is assigned the user's mean consumption value. While this approach disregards all short-term variation, it does capture the overall magnitude of consumption. Therefore, it performs better than a truly random or noise-based prediction.
- 2) **Realistic forecast:** a consumption forecast generated by the XGBoost model developed in this work. This model

incorporates temporal features and historical patterns to approximate actual load dynamics.

- 3) **Perfect foresight:** the actual future load profile is assumed to be perfectly known in advance. This represents an upper bound for predictive performance.

This comparison serves two purposes: (i) to evaluate the effectiveness of the forecasting model used in this thesis, and (ii) to quantify the sensitivity of the RHLP algorithm to varying levels of forecast accuracy.

Table IV summarizes the resulting cost components for each scenario. Moving from a flat profile to a realistic forecast yields a cost reduction of approximately 1.9%. This confirms that even a moderately accurate forecast contributes to more effective control. The improvement from realistic to perfect foresight adds another 2.3% reduction, showing that further gains are possible if prediction accuracy improves.

While forecast accuracy has a clear influence—especially on peak shaving and overall net cost—the RHLP algorithm demonstrates a certain degree of robustness: even the least informed case (RHLP 1) still performs reasonably well. This suggests that the optimization framework is able to handle moderate inaccuracies without dramatic performance losses.

TABLE IV: Impact of forecast quality on RHLP algorithm performance

Algorithm	RHLP 1	RHLP 2	RHLP 3
Forecast type	average	XGBoost	perfect
Energy cost (import)	3632.28	3663.05	3484.51
Injection revenue	2107.87	2111.93	2058.12
Total grid cost	4239.91	4191.96	4064.55
Total levies	1348.57	1343.49	1326.25
Imbalance penalty	0.00	0.00	0.00
Total tariff	7112.89	6980.17	6817.19
% Cost reduction vs. RHLP 1	–	1.87%	4.16%

C. Performance under Dynamic Contracts

In this analysis, the assumption that a user following the baseline algorithm would not opt for a dynamic contract is relaxed. This allows us to explore a scenario in which large consumers are required to participate in time-varying energy markets—a requirement that currently applies to consumers with an annual consumption above 100 MWh and equipped with an AMR meter, as defined by Flemish regulation [8].

Under these dynamic tariff conditions, both algorithms were evaluated across six industrial consumption profiles. The RHLP algorithm achieved an average cost reduction of **18.71%**, highlighting its ability to exploit price variability more effectively than the baseline approach.

Figure 4 illustrates the percentage cost savings of the RHLP algorithm compared to the baseline for each individual user. The RHLP strategy consistently outperforms the rule-based benchmark across all profiles.




Fig. 4: Percentage savings of the RHL algorithm under dynamic contract per user

These results confirm that predictive, price-sensitive battery control under dynamic electricity contracts yields substantial benefits across various industrial profiles.

D. Effect of Battery Capacity

For user 12, battery capacity was varied from 25 to 350 kWh to assess its impact on performance. As illustrated in Figure 5, the RHL algorithm (red line) consistently achieves lower total energy costs from 50 kWh onwards, while the baseline algorithm (blue line) shows only a gradual cost reduction. The cost advantage of RHL increases with larger battery sizes, due to its ability to exploit broader price arbitrage opportunities and to mitigate peaks more effectively.

In general, the RHL algorithm requires a minimum amount of storage capacity to function effectively. This threshold depends on the user profile. Below this threshold, the battery lacks sufficient flexibility to shift energy in response to price signals or anticipated peaks. Consequently, the algorithm cannot generate a consistent economic benefit from forecast-based optimization unless a minimum level of storage is available.




Fig. 5: Total cost as a function of battery capacity (kWh)

VII. CONCLUSION OF FINDINGS

Overall, the RHL algorithm proves to be a robust and high-performing strategy under dynamic electricity pricing—particularly when battery capacity and load flexibility are

sufficient. Under the tested conditions and across the evaluated user profiles, the RHL algorithm—operating under a dynamic contract—achieved an average cost reduction of **4.91%** across all users, compared to the baseline algorithm, which was evaluated under a variable contract with average monthly or quarterly prices.

Additionally, a second comparison was made against a baseline operating under a dynamic contract with hourly Belpex prices, as this contract type is increasingly mandatory for large industrial consumers. In this context, RHL achieved a notable average cost reduction of **18.71%**.

These results demonstrate that forecast-based control strategies allow for measurable cost reductions, especially for flexible users with sufficient storage. However, the benefits remain modest—even under perfect forecasts—indicating a structural upper bound to what battery optimization alone can achieve. While RHL clearly outperforms static, rule-based approaches, especially in volatile price environments, the relative gains do not drastically alter the economic case for batteries in isolation.

To conclude, leveraging a battery to benefit from hourly price dynamics is worthwhile and increasingly relevant in the context of dynamic tariffs. Yet, it is not a silver bullet for unlocking large-scale profitability. Its strength lies in supporting a broader energy strategy—one that combines flexibility, accurate forecasting, and integrated planning.

REFERENCES

- [1] Elia Transmission Belgium, “Belgian electricity system blueprint 2035–2050,” 2024, accessed: 2025-05-21. [Online]. Available: https://www.elia.be/en/press/2024/09/20240924_elia-publishes-blueprint-for-the-belgian-electricity-system-2035-2050
- [2] Elia, “Belgian bidding zone day-ahead reference price,” 2025, accessed: 2025-05-21. [Online]. Available: <https://www.elia.be/en/grid-data/transmission/day-ahead-reference-price>
- [3] W.-C. Tsai, C.-S. Tu, C.-M. Hong, and W.-M. Lin, “A review of state-of-the-art and short-term forecasting models for solar pv power generation,” *Energies*, vol. 16, no. 14, p. 5436, 2023.
- [4] T. Chen and C. Guestrin, “Xgboost: A scalable tree boosting system,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2016, pp. 785–794.
- [5] I. E. de Estudios Superiores Loyola (IEESL), “Sizing of photovoltaic systems for self-consumption without surpluses through on-site measurements: Case study of the dominican republic,” *Renewable Energy*, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0960148124014903>
- [6] RatedPower, “Simulating east-west configurations with ratedpower,” 2021. [Online]. Available: <https://ratedpower.com/blog/east-west-solar-panels/>
- [7] G. Deconinck and S. V. den Broeck, “Assessing the benefits of decentralised residential batteries for load shaping and peak shaving,” *Energy Reports*, vol. 6, pp. 1234–1245, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2352152X20301669>
- [8] Fluvius, “Wordt een dynamisch contract verplicht bij een amr-meter?” 2023, geraadpleegd op 13 mei 2025. [Online]. Available: <https://www.fluvius.be/nl/thema/dynamisch-contract>

Inhoudsopgave

Abstract	iv
Lijst van figuren	xiii
Lijst van tabellen	xv
1 Inleiding	1
2 Voorspelling	4
2.1 Prijsinformatie en beperkingen	4
2.2 Voorspelling van PV-opbrengst	5
2.3 Keuze van de voorspellingstechniek	5
2.4 Werking van XGBoost	10
2.5 XGBoost toegepast	13
2.5.1 Features	13
2.5.2 Hyperparameters	15
2.5.3 Evaluatiemethoden	15
2.5.4 Invloed van de features	16
3 Algoritmes	19
3.1 Basisalgoritme	19
3.1.1 Virtuele opsplitsing van de batterijcapaciteit	19
3.1.2 Fase 1: Zelfverbruikoptimalisatie	20
3.1.3 Fase 2: Peak shaving	20
3.1.4 Samenvatting van het basisalgoritme	21
3.2 Rolling Horizon Linear Programming-algoritme	23
3.2.1 Lineaire optimalisatie	24
3.2.2 Implementatie van Rolling Horizon Lineaire Programmatie	25
3.2.3 Implementatie van lineaire optimalisatie	27
3.2.4 Wiskundige formulering	29

4 Berekening en keuze van parameters	34
4.1 PV-installatie	34
4.2 Batterijcapaciteit	35
4.3 Peakshavingdrempel	36
4.4 Type contract	36
4.4.1 Variabel contract	37
4.4.2 Dynamisch contract	37
5 Resultaten	38
5.1 Vergelijking tussen het basisalgoritme en het RHLP-algoritme	39
5.1.1 Dynamisch contract	42
5.1.2 Perfecte voorspelling: theoretische bovengrens	44
5.1.3 Kwaliteit van de voorspelling	46
5.2 Sensitiviteitsanalyse	47
5.2.1 Batterijcapaciteit	47
5.2.2 Resultaten voor verschillende profielen	49
5.2.3 Invloed van verschillende marktprijzen	57
5.3 Gedrag van het RHLP-algoritme	61
5.3.1 Analyse van piekmomenten door voorspellingsfouten: vergelijking met perfect voorspelde situatie	61
5.3.2 Laadbeslissing op basis van dynamische prijzen	63
5.3.3 Vaststellingen over gedrag RHLP-algoritme	63
6 Conclusie	65
7 Vervolgonderzoek	68
8 Maatschappelijke reflectie	71
9 Verantwoord gebruik van generatieve artificiële intelligentie	75
Bijlagen	81
A Verschillende verbruiksprofielen	82
Bijlage A	82

Lijst van figuren

2.1	Werkelijke vs voorspelde verbruik - Long Short-Term Memory (LSTM)-model	9
2.2	Werkelijke vs voorspelde verbruik - XGBoost-model	9
2.3	Feature importance volgens het XGBoost-model voor verbruiker 15	18
3.1	Schematisch overzicht van het basisalgoritme voor batterijoptimalisatie . .	22
3.2	Schematisch overzicht van het Rolling Horizon Linear Programming (RHLP)- algoritme	32
5.1	Vergelijking van kostencomponenten tussen het basisalgoritme en het RHLP- algoritme	40
5.2	Procentuele kostenreductie van het RHLP-algoritme t.o.v. het basisalgo- ritme per verbruiker (realistische contracten)	42
5.3	Procentuele kostenreductie van het RHLP-algoritme t.o.v. het basisalgo- ritme per verbruiker (dynamisch contract)	44
5.4	Vergelijking van absolute kost en relatieve winst in functie van batterijcapaciteit	49
5.5	Scatterplot van F1-score tegenover procentuele winst per verbruiker	51
5.6	Scatterplot van nacht- en weekendverbruik tegenover procentuele winst (t.o.v. basisalgoritme met variabel contract).	53
5.7	Feature importance in het XGBoost-model voor verbruiker 3 (hoog week- endverbruik)	56
5.8	Feature importance in het XGBoost-model voor verbruiker 15 (laag week- endverbruik)	56
5.9	Vergelijking van totale kosten per jaar voor RHLP- en basisalgoritme	57
5.10	Boxplotanalyse van de marktprijzen (Belpex $\times$ RLP) per jaar.	58
5.11	Dagelijkse prijsvariabiliteit (max - min) per jaar	59
5.12	Prijsvariabiliteit per 2-dagenblok in 2021	60
5.13	Vergelijking van de batterijsturing bij XGBoost voorspelling (links) en per- fecte voorspelling (rechts).	62
A.1	Visualisatie historisch verbruik van verbruiker 3.	85

A.2	Werkelijke data en voorspelling van verbruiker3.	86
A.3	Visualisatie historisch verbruik van verbruiker 6.	88
A.4	Werkelijke data en voorspelling van Verbruiker 6.	89
A.5	Visualisatie historisch verbruik van verbruiker 7.	91
A.6	Werkelijke data en voorspelling van verbruiker 7.	92
A.7	Visualisatie historisch verbruik van verbruiker 12.	94
A.8	Werkelijke data en voorspelling van verbruiker 12.	95
A.9	Visualisatie historisch verbruik van verbruiker 15.	97
A.10	Werkelijke data en voorspelling van verbruiker 15.	99
A.11	Visualisatie historisch verbruik van verbruiker 43.	100
A.12	Werkelijke data en voorspelling van verbruiker 43.	102

Lijst van tabellen

2.1	Vergelijking van populaire voorspellingstechnieken voor elektriciteitsverbruik	7
2.2	Geconfigureerde hyperparameters voor het XGBoost-model	15
2.3	Vergelijking van modelprestaties voor verbruiker 15 met en zonder werkdag-feature	17
3.1	Vergelijking tussen RHLP en Model Predictive Control (MPC)	26
5.1	Instellingen van de standaardparameters	39
5.2	Vergelijking van prestaties onder realistische contractomstandigheden	40
5.3	Vergelijking tussen basisalgoritme en RHLP-algoritme met dynamisch contract (verbruiker 12)	43
5.4	Vergelijking tussen basisalgoritme met variabel contract en RHLP-algoritme met perfecte voorspelling	45
5.5	Impact van de kwaliteit van de voorspelling op het RHLP-algoritme	46
5.6	Parameters voor evaluatie batterijcapaciteit	48
5.7	Vergelijking van kosten bij verschillende batterijcapaciteiten	48
5.8	Gerealiseerde winst met werkelijke en perfecte voorspelling.	50
5.9	Overzicht van F1-score en bijhorende winst per verbruiker.	51
5.10	Verband tussen het nacht- en weekendverbruik en de prestaties van het RHLP-algoritme (t.o.v. basisalgoritme met variabel contract).	52
5.11	Verband tussen nacht- en weekendverbruik en winst van RHLP-algoritme (t.o.v. basisalgoritme met dynamisch contract).	54
5.12	Toename in winst van het RHLP-algoritme bij overstap van variabel naar dynamisch contract.	54
5.13	Vergelijking van prestaties tussen basis algoritme en RHLP-algoritme.	57
A.1	Overzicht van het totale verbruik en de verdeling in tijdsblokken.	86
A.2	Evaluatie van de algemene voorspellingsprestaties.	86
A.3	Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 16kW.	86
A.4	Parameterinstellingen voor Verbruiker 3.	87

A.5	Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 3.	87
A.6	Overzicht van het totale verbruik en de verdeling in tijdsblokken.	89
A.7	Evaluatie van de algemene voorspellingsprestaties voor Verbruiker 6. . . .	89
A.8	Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 30kW voor Verbruiker 6.	89
A.9	Parameterinstellingen voor Verbruiker 6.	90
A.10	Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 6.	90
A.11	Overzicht van het totale verbruik en de verdeling in tijdsblokken.	92
A.12	Evaluatie van de algemene voorspellingsprestaties.	92
A.13	Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 30kW.	92
A.14	Parameterinstellingen voor Verbruiker 7.	93
A.15	Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 7.	93
A.16	Overzicht van het totale verbruik en de verdeling in tijdsblokken.	95
A.17	Evaluatie van de algemene voorspellingsprestaties voor verbruiker 12. . . .	95
A.18	Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 4kW voor verbruiker 12.	95
A.19	Parameterinstellingen voor Verbruiker 12.	96
A.20	Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 12.	96
A.21	Overzicht van het totale verbruik en de verdeling in tijdsblokken voor ver- bruiker 15.	98
A.22	Evaluatie van de algemene voorspellingsprestaties voor verbruiker 15. . . .	98
A.23	Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 4kW voor verbruiker 15.	98
A.24	Vergelijking van het basisalgoritme en het RHLP-algoritme voor verbruiker 15.	99
A.25	Overzicht van het totale verbruik en de verdeling in tijdsblokken voor ver- bruiker 43.	101
A.26	Evaluatie van de algemene voorspellingsprestaties voor verbruiker 43. . . .	101
A.27	Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 4kW voor verbruiker 43.	101
A.28	Parameterinstellingen voor verbruiker 43.	102
A.29	Vergelijking van het basisalgoritme en het RHLP-algoritme voor verbruiker 43.	102

Lijst van afkortingen

AI Artificial Intelligence – kunstmatige intelligentie.

AMR Automated Meter Reading – automatische meteropname.

API Application Programming Interface.

ARIMA AutoRegressive Integrated Moving Average.

Belpex Belgian Power Exchange.

C-rate C-rate – verhouding tussen laad- of ontlaadstroom en de capaciteit van een batterij.

DoD Depth of Discharge – mate waarin een batterij ontladen wordt t.o.v. haar totale capaciteit.

F1-score F1-score – harmonisch gemiddelde van precisie en recall bij classificatie.

IEA International Energy Agency – Internationaal Energieagentschap.

LP Linear Programming – lineaire programmering. iv

LSTM Long Short-Term Memory. xiii, 7–10

MAE Mean Absolute Error.

MAPE Mean Absolute Percentage Error.

MPC Model Predictive Control – voorspellende regeltechniek met heroptimalisatie per tijdstap.

PS Peak Shaving.

PV Photovoltaïsch – zonnepaneelinstallatie. iv

PVGIS Photovoltaic Geographical Information System – Europese tool voor zonne-opbrengstvoorspelling.

R² Determinatiewaarde – aandeel verklaarde variantie in regressiemodellen.

Random Forest Random Forest – ensemble decision tree methode.

RHLP Rolling Horizon Linear Programming. iv

RMSE Root Mean Squared Error.

SARIMA Seasonal AutoRegressive Integrated Moving Average.

SoC State of Charge – laadtoestand van een batterij.

SVR Support Vector Regression – regressie met support vector machines.

XGBoost Extreme Gradient Boosting. iv, xiii, 7–10

ZC Zelfconsumptie.

ZV Zelfverbruik.

1

Inleiding

De Belgische energiemarkt ondergaat de laatste jaren een fundamentele transformatie. De uitrol van digitale meters en de toename van hernieuwbare energieproductie leiden tot een dynamischer en onvoorspelbaarder elektriciteitssysteem. Deze evolutie wordt verder versterkt door de snelle toename van het aantal elektrische voertuigen en (in de toekomst) warmtepompen. In dit nieuwe landschap nemen twee concepten een centrale plaats in: **peak shaving** en **zelfconsumptie**.

Peak shaving verwijst naar het verminderen van pieken in het elektriciteitsverbruik, die sinds de invoering van het capaciteitstarief sterk doorwegen in de netkosten. Dit onderdeel van de elektriciteitsfactuur, dat dient voor het vergoeden van de netbeheerders Fluvius en Elia, baseert de netvergoeding deels op het hoogste kwartierverbruik binnen een maand. Het afvlakken van pieken via batterijopslag biedt daarom een directe en substantiële financiële winst.

Zelfconsumptie daarentegen heeft betrekking op het maximaal lokaal gebruiken van de zelfgeproduceerde zonne-energie. Injectie van overtollige elektriciteit op het net levert doorgaans een veel lagere vergoeding op dan de kost van afname. Door aan zelfconsumptie te doen, kunnen bovendien netkosten en heffingen vermeden worden. Verhoogde zelfconsumptie draagt ook bij tot netstabiliteit en decentrale energietransitie. Beide mechanismen – peak shaving en zelfconsumptie – zijn dus niet enkel financieel voordelig, maar ook maatschappelijk relevant.

Om deze doelen te realiseren, werd in het verleden vaak gewerkt met eenvoudige regelgebaseerde algoritmes, zoals het onderzochte **basisalgoritme** in deze studie. Dit algoritme reserveert een deel van de batterijcapaciteit voor peak shaving en een ander deel voor zelfconsumptie, zonder daarbij gebruik te maken van enige voorspelling of prijsinformatie. Het werkt sequentieel, statisch en reactief.

1 Inleiding

Met de opkomst van dynamische elektriciteitscontracten, die de energieprijs op uur-basis of zelfs kwartierbasis laten variëren in functie van marktaanbod, wordt de rol van tijdsinformatie steeds crucialer. Deze prijszetting weerspiegelt dus rechtstreeks de werkelijke marktomstandigheden en stimuleert consumenten om hun verbruik te verschuiven naar momenten van lage prijzen. Dergelijke contracten zijn maatschappelijk relevant, omdat ze flexibiliteit belonen en zo bijdragen aan netbalancing en de integratie van hernieuwbare energie.

Slimme aansturing op basis van toekomstige prijs- en verbruiksverwachtingen kan aanzienlijke meerwaarde creëren. Daarom wordt in deze masterproef een tweede algoritme voorgesteld: het Rolling Horizon Linear Programming (RHLP)-algoritme.

Het RHLP-algoritme baseert zich op voorspellingen van het elektriciteitsverbruik (via XGBoost), de PV-opbrengst en dynamische prijzen om bij elke tijdstap het batterijgebruik over een venster van 48 uur te optimaliseren. Deze aanpak laat toe om vooruitziend te plannen en optimaal te reageren op prijssignalen. Omdat de performantie van het algoritme sterk afhangt van de kwaliteit van de inputvoorspellingen, focust het eerste deel van dit onderzoek op het bepalen van een geschikte voorspellingsmethode voor het elektriciteitsverbruik.

De centrale onderzoeksvraag van deze masterproef is dan ook als volgt:

Kan een voorspellingsgestuurd optimalisatie-algoritme (RHLP) een eenvoudige heuristisch basisalgoritme verslaan in termen van totale energiekost, binnen het kader van dynamische elektriciteitsprijzen en het capaciteitstarief?

Om dit te onderzoeken, worden de prestaties van beide algoritmes vergeleken onder diverse realistische omstandigheden: met en zonder 'betekenisvolle' verbruiksvoorspelling, onder variabele en dynamische contracten, bij verschillende verbruiksprofielen, en voor uiteenlopende batterijcapaciteiten.

Daarnaast wordt in deze thesis antwoord gezocht op enkele bijkomende onderzoeksvragen:

- *In welke mate is de kwaliteit van de verbruiksvoorspelling bepalend voor de prestaties van het RHLP-algoritme?*
- *Welke types verbruikers halen het meeste voordeel uit voorspellingsgestuurde optimalisatie? Is dit afhankelijk van het tijdstip van verbruik (bv. dalurenverbruik) of de voorspelbaarheid van het verbruiksprofiel?*

1 Inleiding

- *Hoe gevoelig zijn de algoritmes voor marktprijsfluctuaties?* Leidt meer prijsverschommelingen altijd tot betere optimalisatiewinsten?
- *Wat zijn de zwakke punten van het RHLP-algoritme?* Hoe gaat het om met imperfecte voorspellingen, en waar treden er fouten op?

Doorheen de studie wordt systematisch nagegaan in welke contexten het RHLP-algoritme effectief superieur is aan het basisalgoritme, en wanneer eenvoudige regelgebaseerde sturing voldoende blijkt. De bevindingen dragen bij aan de kennis over slimme batterijaansturing in een evoluerende energiemarkt en bieden waardevolle inzichten voor zowel industriële gebruikers als beleidsmakers.

Deze thesis is opgebouwd als volgt. In hoofdstuk 1 wordt de context geschetst en het probleemkader toegelicht. Vervolgens behandelt hoofdstuk 2 de gebruikte data en modellen, inclusief de aanpak voor verbruikvoorspelling met XGBoost. In hoofdstuk 3 worden de algoritmes besproken die instaan voor de sturing van het batterijsysteem, met focus op het ontwikkelde RHLP-algoritme. Hoofdstuk 4 beschrijft de keuze en berekening van belangrijke parameters zoals batterijcapaciteit, peakshavingdrempel en contracttype. In hoofdstuk 5 worden de resultaten gepresenteerd van de simulaties en wordt de performantie van beide algoritmes vergeleken onder verschillende scenario's. Hoofdstuk 6 formuleert de belangrijkste conclusies, waarna in hoofdstuk 7 suggesties voor toekomstig onderzoek worden aangereikt. Tot slot bevat hoofdstuk 8 een maatschappelijke reflectie rond duurzaamheid, ethiek en de bredere toepasbaarheid van het algoritme.

2

Voorspelling

Dit hoofdstuk behandelt de opzet en toepassing van voorspellingen die noodzakelijk zijn voor de werking van het optimalisatie-algoritme. Om het batterijsysteem efficiënt te sturen, is het cruciaal om op voorhand een goed beeld te hebben van het verwachte elektriciteitsverbruik, de PV-opbrengst en de prijsinformatie op de energiemarkt. Deze voorspellingen maken het mogelijk om vooruitziende en datagedreven beslissingen te nemen die leiden tot lagere energiekosten en een hogere zelfconsumptie.

Eerst wordt ingegaan op de beschikbare prijsinformatie en de veronderstellingen daaromtrent binnen dit onderzoek. Vervolgens wordt toegelicht hoe de PV-opbrengst wordt benaderd. Daarna volgt een vergelijking van verschillende technieken voor verbruiksvoorspelling, met uiteenzetting van de gekozen methode: XGBoost. De onderliggende werking van dit algoritme wordt besproken, evenals de concrete implementatie en de evaluatie van de prestaties. Tot slot wordt aangetoond hoe de opgestelde features bijdragen aan een accuraat voorspellingsmodel voor industriële verbruikers.

2.1 Prijsinformatie en beperkingen

Een cruciale component binnen het optimalisatieproces betreft de beschikbaarheid van prijsinformatie. Aangezien het batterijsysteem beslissingen neemt op basis van toekomstige elektriciteitsprijzen, is het essentieel om te weten in welke mate deze prijzen vooraf gekend zijn, en hoe daarmee binnen het model wordt omgegaan. Voor eindgebruikers zijn deze prijzen doorgaans beschikbaar vanaf 11 tot maximaal 35 uur voor het moment van verbruik [1].

In deze thesis werd verondersteld dat de prijzen tot 48 uur in de toekomst volledig gekend zijn. Deze keuze is afgestemd op de lengte van het voorspellingsvenster voor het elektriciteitsverbruik, dat eveneens 48 uur bedraagt. Door zowel prijs- als verbruiksin-

2 Voorspelling

formatie over dezelfde horizon beschikbaar te stellen, wordt een consistente basis gecreëerd voor de optimalisatiebeslissingen binnen het algoritme. Deze vereenvoudiging laat toe om het algoritme te evalueren in een ideaal scenario waarbij geen foutenmarge op de prijsvoorspelling bestaat. Hoewel deze aanpak toelaat om het potentieel van het optimalisatiemodel zuiver te beoordelen, vormt dit uiteraard een beperking ten opzichte van de werkelijkheid.

Om deze vereenvoudiging in een toekomstige toepassing te omzeilen, zijn er twee mogelijke strategieën. Een eerste mogelijkheid is om de prijshorizon op te splitsen: voor de periode waarin de prijzen effectief gekend zijn (doorgaans tot 11 à 35 uur in de toekomst) kan gewerkt worden met echte marktdata, terwijl voor de resterende tijdstappen binnen de optimalisatiehorizon voorspellingen gegenereerd worden op basis van historische Belpex-data. Een alternatieve aanpak is om de lengte van het verbruiksvoorspellingsvenster – en dus ook van de optimalisatiehorizon – in te korten tot bijvoorbeeld 11 uur, zodat er uitsluitend gewerkt wordt met gekende prijzen. Beide strategieën kunnen het model dichterbij een praktische implementatie brengen, zonder al te veel in te boeten op nauwkeurigheid.

2.2 Voorspelling van PV-opbrengst

Aangezien er reeds zeer performante methoden bestaan om de opbrengst van een PV-installatie te voorspellen, wordt hier in deze thesis niet verder op ingegaan. Er wordt verondersteld dat de PV-opbrengst op voorhand nauwkeurig beschikbaar is. Recente literatuurstudies rapporteren dat geavanceerde modellen op basis van kunstmatige neurale netwerken of hybride technieken een gemiddelde voorspellingsfout (MAPE) van slechts 2 tot 7% kunnen behalen [2]. Indien men er toch voor zou kiezen om ook de PV-opbrengst te modelleren, kan dit op een analoge manier gebeuren als bij de verbruiksvoorspelling, met bijkomende invoerparameters zoals zonnestraling, temperatuur en bewolgingsgraad.

2.3 Keuze van de voorspellingstechniek

In de literatuur worden uiteenlopende technieken aangereikt voor het voorspellen van elektriciteitsverbruik. Deze technieken kunnen globaal onderverdeeld worden in drie categorieën: klassieke statistische modellen, traditionele machine learning-methoden en deep learning-benaderingen.

2 Voorspelling

Klassieke statistische modellen, zoals ARIMA en SARIMA, veronderstellen een zekere mate van stationariteit in de tijdsreeks en zijn voornamelijk geschikt voor lineaire patronen met seizoensinvloeden. Ze zijn eenvoudig te interpreteren en vereisen relatief weinig data, wat hen aantrekkelijk maakt in contexten met beperkte informatie of wanneer transparantie van het model belangrijk is. De voorspellingskracht van dergelijke modellen is echter beperkt wanneer de onderliggende tijdsreeks sterk niet-lineair of volatiel is, zoals vaak het geval is bij individuele verbruiksprofielen [3].

Binnen de machine learning-klasse worden technieken zoals Random Forest en Support Vector Regression (SVR) frequent ingezet. Random Forest is robuust tegen overfitting en werkt goed op gestructureerde tabulaire data, maar mist vaak de verfijning om sequentiële afhankelijkheden in tijdreeksen te capteren [4]. SVR heeft zich bewezen als stabiele voorspeller bij kleinere datasets en presteert sterk in situaties met duidelijke patronen. Het algoritme is echter gevoelig voor de keuze van hyperparameters, en zijn schaalbaarheid is beperkt bij grotere toepassingen [5].

Deep learning-algoritmen zoals Long Short-Term Memory-netwerken (LSTM) zijn specifiek ontworpen voor sequentiële data en zijn in staat om langetermijnafhankelijkheden in tijdreeksen te modelleren. LSTM-netwerken behalen vaak hoge nauwkeurigheid in voorspellingstaken waar temporele samenhang centraal staat, maar vereisen doorgaans een grote hoeveelheid trainingsdata, intensieve rekenkracht en complexe hyperparameterafstemming om tot optimale resultaten te komen [6], [7]. Daarnaast ontbreekt het deze modellen vaak aan transparantie, wat hun toepasbaarheid in operationele omgevingen kan bemoeilijken.

Ten slotte is er XGBoost (Extreme Gradient Boosting), een ensemble-algoritme dat gebaseerd is op decision trees. XGBoost geniet brede populariteit vanwege zijn combinatie van snelheid, nauwkeurigheid en robuustheid. Het presteert bijzonder goed op gestructureerde datasets zonder uitgesproken sequentiële structuur, en is relatief ongevoelig voor ontbrekende waarden of outliers. Hoewel het algoritme minder geschikt is voor taken met expliciete tijdsafhankelijkheid, biedt het wel een hoge voorspellingskracht bij verbruiksdata die grotendeels bepaald wordt door regelmatige, herhaalde patronen [8], [9].

Tabel 2.1 geeft een overzicht van de besproken technieken, samen met hun voornaamste voordelen en beperkingen, zoals gerapporteerd in de literatuur.

2 Voorspelling

Tabel 2.1: Vergelijking van populaire voorspellingstechnieken voor elektriciteitsverbruik

Techniek	Voordelen	Nadelen	Bronnen
ARIMA/SARIMA	Goed interpreteerbaar, geschikt voor stationaire data	Beperkt bij niet-lineaire relaties	[3]
Random Forest	Robuust, goede baseline performance	Traag bij grote datasets, moeilijk interpreteerbaar	[4]
SVR (Support Vector Regression)	Goed bij kleine datasets, stabiel	Gevoelig voor parameterkeuze, matige schaalbaarheid	[5]
LSTM (Long Short-Term Memory)	Sterk bij complexe tijdsstructuren	Hoge trainingskost, veel data vereist	[6], [7]
XGBoost	Hoge accuraatheid, snelle inferentie, goed bij tabulaire data	Minder geschikt voor sterk sequentiële data	[8], [9]

Bij de selectie van geschikte voorspellingsmodellen werd gekeken naar zowel de kenmerken van de beschikbare verbruiksdata als de sterktes van de verschillende algoritmes uit de literatuur. De focus ligt op industriële gebruikers, waarbij het verbruiksprofiel doorgaans stabiel en repetitief is, met terugkerende dagschema's en werkweekstructuren. Dergelijke data zijn goed modelleerbaar via algoritmen die patronen in gestructureerde tabulaire gegevens herkennen, maar recente verbruikscontext — zoals de dagen vlak vóór de voorspelling — kan ook relevante informatie bevatten.

Daarom werden twee complementaire technieken geselecteerd voor verdere analyse: LSTM, een deep learning-model dat ontworpen is om complexe temporele afhankelijkheden te modelleren via sliding windows; en XGBoost, een krachtig en efficiënt ensemble-algoritme gebaseerd op decision trees, dat uitblinkt in snelheid en nauwkeurigheid bij gestructureerde data met beperkte sequentiële complexiteit. Beide modellen vertegenwoordigen een fundamenteel verschillende voorspellingsstrategie — tijdreeksgericht versus patroonherkenning — en hun vergelijking biedt waardevolle inzichten in de toepasbaarheid binnen het optimalisatieprobleem.


2 Voorspelling

Vergelijking van LSTM en XGBoost Uit figuur 2.1 en figuur 2.2 blijkt hoe goed respectievelijk een LSTM-model en een XGBoost-model erin slagen het werkelijke verbruik te voorspellen. Hoewel het LSTM-model op het eerste gezicht accuraat lijkt, is deze vergelijking niet volledig eerlijk. Beide modellen werden getraind op historische data uit 2014 en 2015. Voor de voorspelling van een bepaalde dag in 2016 maakte het LSTM-model echter gebruik van een sliding window met de 21 dagen aan verbruiksdata die onmiddellijk voorafgaan aan de voorspelde dag. Dit betekent dat het model telkens over recente en zeer relevante informatie beschikte bij het maken van voorspellingen. Het XGBoost-model daarentegen ontving geen extra input en moest zich volledig baseren op patronen aangeleerd tijdens de trainingsfase. Dit fundamentele verschil in aanpak geeft het LSTM-model een tijdelijk informatievoordeel, wat de vergelijking tussen beide modellen beïnvloedt.


Een rechtstreekse numerieke vergelijking tussen beide modellen is echter niet zinvol, aangezien ze fundamenteel verschillen in hoe en waarvoor ze ingezet werden. Het LSTM-model voorspelt telkens slechts twee dagen vooruit en doet dat op basis van de 21 meest recente dagen aan verbruiksdata voorafgaand aan de voorspelde periode. Het model beschikt dus over zeer actuele contextinformatie bij elke voorspelling. Het XGBoost-model daarentegen werd één keer getraind op historische data (2014–2015) en vervolgens toegepast op het volledige jaar 2016, zonder extra input of sliding contextvensters. Een vergelijking tussen een korte-termijnvoorspelling met rijke context versus een jaarvoorspelling zonder aanvullende informatie zou numeriek misleidend zijn.

Daarom werd gekozen voor een visuele evaluatie van de voorspellingen. De grafieken tonen dat het XGBoost-model ondanks deze beperktere context toch in staat is om realistische trends en piekmomenten accuraat te reconstrueren.

2 Voorspelling



Figuur 2.1: Werkelijke vs voorspelde verbruik - LSTM-model



Figuur 2.2: Werkelijke vs voorspelde verbruik - XGBoost-model

Op basis van deze evaluatie werd in deze masterproef gekozen voor XGBoost. De keuze werd gemaakt op basis van een combinatie van praktische en technische overwegingen. In tegenstelling tot het LSTM-model, dat real-time voorspellingen maakt op basis van telkens de 21 meest recente dagen, genereert XGBoost zijn voorspellingen in één keer voor de volledige periode. Deze vooraf gegenereerde batchvoorspelling heeft

2 Voorspelling

als belangrijk voordeel dat ze veel sneller verwerkt kan worden binnen het optimalisatie-algoritme, wat de totale rekentijd aanzienlijk verlaagt. Dit verschil in gebruik — real-time sliding window versus offline batchverwerking — maakt XGBoost bijzonder geschikt voor toepassingen waarbij snelheid en schaalbaarheid centraal staan.

Daarnaast biedt XGBoost nog andere voordelen:

- **Hoge voorspellingsaccuraatheid:** XGBoost behoort tot de best presterende algoritmes voor load forecasting op korte termijn, zeker bij gestructureerde gegevens met beperkte tijdsafhankelijkheid [8].
- **Schaalbaarheid en snelheid:** het algoritme vereist minder trainingstijd dan deep learning-modellen zoals LSTM, en laat toe om snel en efficiënt batchvoorspellingen uit te voeren, wat cruciaal is voor de looptijd van het optimalisatieproces.
- **Robuustheid en transparantie:** XGBoost is minder gevoelig voor overfitting dankzij ingebouwde regularisatie en biedt transparante output via feature importance en decision paths.
- **Beperkte vereisten voor preprocessing:** het algoritme presteert goed met relatief weinig datatransformatie, en kan overweg met ontbrekende waarden of uitschieters.

In toekomstig onderzoek kan het gebruik van hybride modellen of deep learning-methoden alsnog interessant zijn, zeker bij grotere datasets of sterk sequentieel gedrag in het verbruik. Voor deze masterproef bood XGBoost echter de meest geschikte combinatie van nauwkeurigheid, efficiëntie en praktische toepasbaarheid.

2.4 Werking van XGBoost

XGBoost (Extreme Gradient Boosting) is een krachtig en efficiënt machine learning-algoritme dat behoort tot de familie van gradient boosting-methoden. Het is ontworpen om hoge voorspellingsnauwkeurigheid te behalen, zelfs bij gestructureerde data met beperkte tijdsstructuur, en tegelijkertijd schaalbaar te blijven voor grote datasets. De methode werd geïntroduceerd door Chen en Guestrin [10].

De kern van XGBoost is het iteratief verbeteren van een ensemble van zwakke voorspellers, meestal beslissingsbomen. Op elke iteratiestap t wordt een nieuwe beslissingsboom $f_t(x)$ toegevoegd die de fouten van het bestaande model probeert te corrigeren. De cumulatieve voorspelling van het model na t iteraties is:

2 Voorspelling

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) \quad (2.1)$$

waarbij f_k regressiebomen zijn en x_i de inputkenmerken van datapunt i .

XGBoost optimaliseert een objectieve functie die bestaat uit twee componenten: een verliesfunctie L , en een regularisatieterm Ω . Voor regressietaken is de kwadratische fout een veelgebruikte keuze:

$$L(y_i, \hat{y}_i) = (y_i - \hat{y}_i)^2 \quad (2.2)$$

Deze keuze is populair omdat ze grote fouten sterker afstraft dan kleine, waardoor het model prioriteit geeft aan het corrigeren van de grootste afwijkingen. Bovendien is deze verliesfunctie wiskundig aantrekkelijk: ze is continu, differentieerbaar en convex.

- **Continuïteit** voorkomt abrupte sprongen in de fout, wat het optimalisatieproces stabiel maakt.
- **Differentieerbaarheid** laat toe om gradiënten te berekenen, nodig voor gradiënt-gebaseerde optimalisatie.
- **Convexiteit** garandeert dat de functie slechts één globaal minimum heeft, wat zorgt voor betrouwbaarheid tijdens het leerproces.

Omdat XGBoost bovendien gebruikmaakt van een tweede-orde Taylor-benadering — waarbij ook de kromming van de verliesfunctie in rekening wordt gebracht — zijn deze eigenschappen niet alleen voordelig, maar zelfs noodzakelijk voor een stabiel en efficiënt leerproces [10].

De regularisatieterm Ω beperkt de complexiteit van de bomen om overfitting tegen te gaan:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (2.3)$$

waarbij T het aantal bladeren in de boom is, w_j de gewichten van die bladeren, en γ en λ hyperparameters zijn. Intuïtief gezien kun je de regularisatieterm beschouwen als een snoeimes voor de boom: hoe meer bladeren en hoe zwaarder ze wegen in de voorspelling, hoe complexer en mogelijk overfit het model wordt. De regularisatieterm

2 Voorspelling

beperkt het aantal bladeren én dempt hun invloed, zodat het model beheersbaar en generaliseerbaar blijft.

De volledige objectieve functie die XGBoost optimaliseert is:

$$Obj^{(t)} = \sum_{i=1}^n L(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (2.4)$$

Om deze efficiënt te optimaliseren, past XGBoost een tweede-orde Taylor-uitbreiding toe op de verliesfunctie:

$$L(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) \approx L(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \quad (2.5)$$

waarbij:

$$g_i = \frac{\partial L}{\partial \hat{y}_i^{(t-1)}} \quad (\text{de eerste afgeleide}) \quad (2.6)$$

$$h_i = \frac{\partial^2 L}{\partial (\hat{y}_i^{(t-1)})^2} \quad (\text{de tweede afgeleide}) \quad (2.7)$$

Deze benadering laat toe om de splitsingen in de bomen zo te kiezen dat de verbetering in de objectieve functie maximaal is. Dit resulteert in een snellere en nauwkeurigere trainingsprocedure.

Technische troeven van XGBoost Naast de wiskundige elegantie beschikt XGBoost over implementatievoordelen die het bijzonder krachtig maken voor grote datasets en praktische toepassingen:

- **Parallele verwerking:** bij het bouwen van een boom bekijkt XGBoost alle mogelijke splitsingen tegelijk, in plaats van stap voor stap. Dit maakt het mogelijk om verschillende berekeningen gelijktijdig uit te voeren op meerdere processor-kernen, wat de training aanzienlijk versnelt [10].
- **Omgaan met ontbrekende waarden:** in plaats van vooraf ontbrekende data te moeten invullen, leert XGBoost zelf tijdens het trainen wat de beste standaard-richting is voor ontbrekende waarden. Hierdoor blijft de modelprestatie behouden zonder manuele tussenkomst of extra preprocessing.

2 Voorspelling

- **Robuustheid tegen outliers:** beslissingsbomen splitsen op drempelwaarden, niet op gemiddelden, waardoor extreme waarden weinig invloed hebben op het model.
- **Feature importance:** na training kan de relatieve bijdrage van elke inputvariabele worden geëvalueerd via metriekgebaseerde scores zoals 'gain', 'cover' of 'frequency'. Deze analyse maakt geen deel uit van het optimalisatieproces, maar wordt achteraf berekend op basis van de boomstructuur.

Samengevat biedt XGBoost een combinatie van wiskundige precisie, computationele efficiëntie en praktische toepasbaarheid, wat het bijzonder geschikt maakt voor het voorspellen van elektriciteitsverbruik met tabulaire datasets. Deze beschrijving is gebaseerd op de oorspronkelijke publicatie van Chen en Guestrin [10].

2.5 XGBoost toegepast

In deze sectie wordt toegelicht hoe XGBoost werd ingezet voor de voorspelling van het kwartierverbruik. Het model werd getraind op data uit 2014 en 2015 en geëvalueerd op het jaar 2016.

2.5.1 Features

XGBoost is een feature-gebaseerd model, wat betekent dat de kwaliteit en relevantie van de gebruikte invoervariabelen — ook wel 'features' genoemd — een grote invloed hebben op de voorspelnauwkeurigheid. Features zijn afgeleide kenmerken of informatievelden die het model gebruikt om patronen in het verbruik te herkennen. In tegenstelling tot deep learning-modellen die zelf kenmerken kunnen leren uit ruwe input, steunt XGBoost op expliciet opgegeven features. Een doordachte selectie en constructie van deze features — het zogenaamde feature engineering — is dan ook essentieel om het potentieel van het model ten volle te benutten.

De features bestonden uit zowel temporele als kalendergerelateerde variabelen, waaronder: uur van de dag, dag van de week, maand, kwartiernummer binnen de dag, Fourier-componenten (met dagelijkse en wekelijkse periodiciteit) en een samengestelde indicatorvariabele voor werkdag. Deze keuzes zijn ingegeven door het verbruikspatroon van industriële gebruikers, die doorgaans duidelijke ritmes vertonen op week-, dag- en uurbasis. Fourier-termen werden toegevoegd om dergelijke herhalende patronen op continue wijze te modelleren.

2 Voorspelling

De *werkdag*-feature werd handmatig ontworpen als een samengestelde variabele die zowel officiële feestdagen als typische brugdagen in rekening brengt. Deze informatie werd echter niet afzonderlijk als feature opgenomen: de afzonderlijke indicatoren voor feest- en brugdagen dienden enkel als input voor de werkdagbepaling. Daarnaast werd het weekverloop van het verbruik geanalyseerd om vast te stellen hoeveel dagen per week als werkdag kunnen gelden. Standaard werd uitgegaan van een vijfdaagse werkweek (maandag tot en met vrijdag), maar indien het gemiddelde verbruik op zaterdagen duidelijk hoger lag dan op zondagen — en dichter aanleunde bij dat van weekdagen — werd zaterdag eveneens als werkdag gecodeerd. Zo werd de werkdagindicator afgestemd op het daadwerkelijke gebruikspatroon van elke gebruiker.

De *Fourier*-features zijn gebaseerd op het principe van cyclische tijds codering. Tijd in kwartieren (0–95) of dagen (0–6) is cyclisch van aard: na kwartier 95 komt weer 0, na zondag weer maandag. In plaats van deze tijdstippen als lineaire getallen te coderen, worden sinus- en cosinusfuncties gebruikt die deze periodiciteit vastleggen. Zo wordt bijvoorbeeld het dagverloop gemodelleerd via `cos_96_1` en `sin_96_1`, de eerste harmonische over 96 kwartieren. Hogere harmonischen (zoals `cos_96_2` of `cos_672_3`) modelleren fijnere variaties binnen het dag- of weekpatroon.

Ter bevordering van de leesbaarheid en consistentie worden de technische aanduidingen van de Fourier-features in deze masterproef vereenvoudigd tot herkenbare labels. Onderstaand overzicht toont de gebruikte benamingen en hun betekenis.

- `cos_96_1` → **Dagritme – HC** (hoofcomponent): eerste golf van het dagritme, bijvoorbeeld het verschil tussen ochtend- en avondverbruik.
- `cos_672_1` → **Weekritme – HC**: eerste golf van het weekritme, zoals het verschil tussen weekdagen en weekend.
- `cos_96_2`, `cos_672_2` → **Dagritme/Weekritme – D1**: subtielere patronen binnen het dag- of weekverloop (detailniveau 1).
- `sin_*` → **S1, S2, S3**: bijbehorende faseverschuivingen van de respectieve kosinuscomponenten (sinuscomponenten).

Deze aanpak laat toe om met een beperkt aantal continue features toch complexe cyclische gedragspatronen te modelleren zonder honderden dummyvariabelen. Het verhoogt ook de robuustheid van het model bij kleine tijdsverschuivingen.

2 Voorspelling

2.5.2 Hyperparameters

Het model werd geconfigureerd met handmatig afgestemde hyperparameters (zie Tabel 2.2) op basis van initieel testwerk, met nadruk op nauwkeurigheid en generaliseerbaarheid. De waarden vallen binnen de ranges die in de literatuur worden aanbevolen [10].

Tabel 2.2: Geconfigureerde hyperparameters voor het XGBoost-model

Hyperparameter	Waarde
n_estimators	10000
max_depth	8
learning_rate	0.002
subsample	0.8
colsample_bytree	0.8
scale_pos_weight	1.5
objective	reg:squarederror
eval_metric	rmse

2.5.3 Evaluatiemethoden

De prestaties van het model werden geëvalueerd op basis van klassieke regressiemetris, namelijk:

- **RMSE (Root Mean Squared Error):** meet de gemiddelde kwadratische afwijking tussen voorspelling en realiteit. Deze metriek is gevoeliger voor uitschieters, aangezien grotere fouten zwaarder doorwegen.
- **MAE (Mean Absolute Error):** geeft de gemiddelde absolute fout tussen voorspelde en werkelijke waarden weer. In tegenstelling tot RMSE is MAE robuuster voor outliers.
- **R^2 -score (Determination Coefficient):** drukt uit welk percentage van de variatie in de werkelijke data verklaard wordt door het model. Een waarde dicht bij 1 wijst op een goede voorspelling; negatieve waarden duiden op een model dat slechter presteert dan het gemiddelde.
- **MAPE (Mean Absolute Percentage Error):** toont het gemiddelde percentage fout ten opzichte van de werkelijke waarden. Deze metriek is intuïtief maar kan vertekend worden bij lage werkelijke waarden.

2 Voorspelling

- **NRMSE (Normalized RMSE):** de RMSE genormaliseerd ten opzichte van het gemiddelde of het maximumverbruik. Dit maakt het mogelijk om prestaties over verschillende verbruikers op een consistente manier te vergelijken.

Daarnaast werd ook het vermogen van het model om **piekmomenten** correct te detecteren geëvalueerd. Hiervoor werd het 80ste percentiel van het werkelijke verbruik gehanteerd als drempelwaarde. Piekdetectie werd vervolgens beoordeeld met:

- **Precision:** het aandeel van de voorspelde pieken dat effectief een werkelijke piek was.
- **Recall:** het aandeel van de werkelijke pieken dat correct werd voorspeld.
- **F1-score:** het harmonisch gemiddelde van precision en recall, dat de balans tussen beide aspecten weerspiegelt.

2.5.4 Invloed van de features

Om het belang van de featureselectie te illustreren, worden in Tabel 2.3 de modelprestaties voor verbruiker 15 vergeleken in twee scenario's: één waarbij de *werkdag*-feature werd opgenomen, en één waarbij deze bewust werd weggelaten. De overige features en hyperparameters bleven identiek. Het verschil in nauwkeurigheid toont duidelijk aan dat de werkdagindicator een grote meerwaarde biedt, zowel voor algemene voorspelnauwkeurigheid als voor piekdetectie.

2 Voorspelling

Tabel 2.3: Vergelijking van modelprestaties voor verbruiker 15 met en zonder `werkdag`-feature


Metric	Met werkdag	Zonder werkdag
Regressie-evaluatie		
RMSE	7.90	14.05
MAE	4.90	9.14
R ² -score	0.636	-0.151
MAPE (%)	50.4	153.5
NRMSE t.o.v. gemiddelde	0.630	1.121
NRMSE t.o.v. maximum	0.140	0.248
Piekdetectie (drempel = 26.07 kWh)		
Precision	0.765	0.481
Recall	0.533	0.532
F1-score	0.629	0.505

Uit deze resultaten blijkt dat het model met de `werkdag`-feature aanzienlijk betere prestaties levert dan het model zonder. De regressiemetrics verbeteren sterk, met een daling van de RMSE van 14.05 naar 7.90 en een stijging van de R²-score van -0.151 naar 0.636. Ook het gemiddelde foutpercentage (MAPE) ligt beduidend lager, wat aangeeft dat de voorspellingen niet alleen nauwkeuriger zijn in absolute zin, maar ook beter afgestemd zijn op het verbruiksniveau.

Voor piekdetectie vertaalt dit zich in een hogere precisie (van 0.481 naar 0.765), wat wijst op een duidelijke afname van foutpositieve meldingen. De F1-score stijgt van 0.505 naar 0.629, wat de algemene balans tussen precisie en recall verbetert. De recall blijft ongeveer gelijk, wat suggereert dat het model met `werkdag`indicator niet méér pieken detecteert, maar wel juistere beslissingen neemt over welke verbruiksstijgingen als piek worden beschouwd. Dit bevestigt het belang van doordachte feature engineering bij het voorspellen van industrieel elektriciteitsverbruik.

Tot slot geeft Figuur 2.3 een overzicht van de relatieve invloed van elke inputvariabele. De zelfontworpen `werkdag`indicator blijkt daarin één van de meest bepalende features te zijn, waarmee de prestatieverschillen uit Tabel 2.3 verder worden ondersteund.

2 Voorspelling



Figuur 2.3: Feature importance volgens het XGBoost-model voor verbruiker 15

Deze combinatie van ritmische en contextuele features laat het model toe om structurele en terugkerende gedragingen in het elektriciteitsverbruik accuraat te capteren.

Samenvattend blijkt XGBoost goed inzetbaar voor het voorspellen van kwartierverbruik bij industriële verbruikers. Door een doordachte combinatie van handmatig geconstrueerde en wiskundig gegenereerde features, in combinatie met een krachtige en transparante algoritmische structuur, slaagt het model erin om zowel globale verbruiksniveaus als piekmomenten met redelijke nauwkeurigheid te voorspellen, zelfs onder beperkte contextinformatie. De gebruikte aanpak biedt bovendien mogelijkheden tot verdere uitbreiding, zoals geautomatiseerde featureselectie of realtime toepassing in een operationele context.

3

Algoritmes

In dit hoofdstuk worden de algoritmes beschreven die het hart vormen van de batterijoptimalisatie binnen deze masterproef. Het primaire doel van deze algoritmes is het verlagen van de energiefactuur. Dit wordt bereikt door het batterijgebruik op een slimme manier aan te sturen, zodat onder andere het zelfverbruik van lokaal opgewekte zonne-energie verhoogd wordt en pieken in het elektriciteitsverbruik worden afgevlakt.

Twee algoritmes staan centraal: het basisalgoritme, dat dient als benchmark en een meer heuristische aanpak volgt, en het Rolling Horizon Linear Programming (RHLP)-algoritme, dat een geavanceerde optimalisatie toepast op basis van PV-opbrengst, verbruiksvoorspellingen en dynamische prijzen. Dit hoofdstuk bespreekt de opbouw, werking en wiskundige achtergronden van beide algoritmes en laat zien hoe ze bijdragen aan een efficiënter energiebeheer.

3.1 Basisalgoritme

Het basisalgoritme dat in dit onderzoek als benchmark wordt gebruikt, bestaat uit twee hoofdfasen die samenwerken om het energieverbruik en de batterijwerking te optimaliseren: zelfverbruikoptimalisatie en peak shaving (PS). Het doel is om zowel de eigen opgewekte energie zo efficiënt mogelijk te benutten als om het piekverbruik te verlagen, met als uiteindelijke doel het verlagen van de energiefactuur.

3.1.1 Virtuele opsplitsing van de batterijcapaciteit

Een belangrijk uitgangspunt in dit algoritme is dat de beschikbare batterijcapaciteit vooraf virtueel wordt opgesplitst in twee afzonderlijke delen: één voor zelfverbruik (ZV) en één voor peak shaving (PS). Deze opsplitsing gebeurt statisch aan het begin van de

3 Algoritmes

simulatie en blijft gedurende de volledige berekeningsperiode ongewijzigd. Het deel dat wordt voorbehouden voor zelfverbruikoptimalisatie wordt in deze masterproef aangeduid als de ZV-capaciteit (zelfverbruikcapaciteit), terwijl het gereserveerde volume voor peak shaving wordt benoemd als de PS-capaciteit (peak shaving-capaciteit). Zo kan bijvoorbeeld 40% van de batterijcapaciteit toegewezen worden aan peak shaving. Zelfs als er zich tijdens de simulatie nooit een piek voordoet, blijft deze 40% PS-capaciteit onaangeroerd voor andere doeleinden.

Hoewel beide batterijdelen formeel een aparte functie hebben, vervullen ze in de praktijk soms elkaars rol — bijvoorbeeld wanneer bij zelfverbruikoptimalisatie toevallig ook een piek wordt afgevlakt. Toch is het belangrijk op te merken dat dit toeval is, en geen onderdeel van het ontwerp: het algoritme behandelt beide functies onafhankelijk en sequentieel.

3.1.2 Fase 1: Zelfverbruikoptimalisatie

In de eerste fase, de zelfverbruikoptimalisatie, wordt op basis van het netto-energieprofiel — het verschil tussen de verbruiks- en de productiecurve — beslist of de batterij moet laden of ontladen binnen de ZV-capaciteit. Bij een overschot aan zonne-energie (negatief nettoverbruik) wordt zoveel mogelijk energie opgeslagen in de batterij, rekening houdend met het resterende volume in de ZV-capaciteit en het maximale laadvermogen.

Bij een tekort (positief nettoverbruik) wordt vanuit dezelfde ZV-capaciteit ontladen, binnen de grenzen van de actuele laadstatus en het maximale ontlaadvermogen. Na elke actie wordt de toestand van de batterij (state of charge) bijgewerkt.

3.1.3 Fase 2: Peak shaving

In de tweede fase wordt peak shaving (PS) toegepast, los van de zelfverbruikoptimalisatie. Deze fase werkt volledig afzonderlijk en is gebaseerd op een piekdetectiemechanisme. Het doel is om het elektriciteitsverbruik af te vlakken zodra het boven een vooraf ingestelde drempel (de zogenaamde cutoff) dreigt uit te stijgen. Op die manier kunnen netkosten en heffingen worden beperkt, aangezien die vaak gebaseerd zijn op het hoogste geregistreerde kwartierverbruik.

Het algoritme controleert elk kwartier of het huidige verbruik onder of boven de cutoff ligt. Als het verbruik onder de drempel zit, en er nog ruimte is in de batterij, dan wordt

3 Algoritmes

deze bijgeladen. Deze laadactie kan zowel gebeuren met overtollige zonne-energie als met netstroom: de batterij wordt in dat geval opgeladen via het net wanneer dat nog mogelijk is binnen de opgelegde limieten. Dit maakt efficiënt gebruik van de beschikbare netcapaciteit, en bereidt de batterij voor op eventuele toekomstige piekmomenten.

Er wordt geladen tot de laagste waarde van drie beperkingen: het verschil tussen de cutoff en het actuele verbruik, het maximaal toelaatbare laadvermogen, en de resterende vrije capaciteit van de batterij.


Wanneer het verbruik de cutoff overschrijdt, zal de batterij ontladen om de piek te dempen. Ook hier gelden beperkingen: de hoeveelheid energie die geleverd kan worden, wordt begrensd door het verschil met de cutoff, de huidige ladingstoestand van de batterij en het maximaal ontladbaar vermogen. Na elke actie wordt de toestand van de batterij aangepast, zodat het systeem de volgende kwartiermeting opnieuw met actuele gegevens kan evalueren.

3.1.4 Samenvatting van het basisalgoritme

Het basisalgoritme biedt een gestructureerde aanpak waarin eerst maximaal wordt ingezet op het benutten van lokaal opgewekte energie (zelfverbruikoptimalisatie), en vervolgens op het reduceren van pieken in het netverbruik (peak shaving). Dit gebeurt steeds binnen de technische grenzen van de batterij (zoals capaciteit, laad- en ontladvermogen en efficiëntie), wat het model bruikbaar maakt voor realistische toepassingen.

Figuur 3.1 geeft een overzicht van de volledige werking. De bovenste helft van de figuur toont het proces voor zelfverbruikoptimalisatie, de onderste helft voor peak shaving. In beide gevallen wordt per kwartier beslist of de batterij moet laden of ontladen, en wordt de toestand van de batterij bijgewerkt op basis van de uitkomst. Deze benchmark vormt het referentiepunt voor de evaluatie van meer geavanceerde algoritmes.

3 Algoritmes



Figuur 3.1: Schematisch overzicht van het basialgoritme voor batterijoptimalisatie

3.2 Rolling Horizon Linear Programming-algoritme

Het RHLP-algoritme bestaat uit verschillende bouwstenen, die hieronder één voor één worden besproken. Vervolgens wordt toegelicht hoe deze componenten samen de werking van het algoritme bepalen.

Voorspelling verbruik

In de sectie over voorspellingstechnieken werd reeds toegelicht hoe het verbruik wordt voorspeld met behulp van XGBoost. In wat volgt wordt deze voorspelling toegepast om de batterij op een slimme manier aan te sturen.

Voorspelling PV-opbrengst

In deze masterproef wordt de PV-opbrengst niet expliciet voorspeld; in plaats daarvan wordt de werkelijke opbrengst als voorspelling beschouwd. De reden hiervoor is dat er reeds tal van performante methoden bestaan om de PV-opbrengst nauwkeurig te voorspellen. In een praktische toepassing kan bijvoorbeeld gebruik gemaakt worden van een API van een bestaand, goed ontwikkeld voorspellingsalgoritme.

Dynamische prijzen

Voor de berekening van de elektriciteitskosten bij dynamische contracten wordt gebruik gemaakt van een flexibele en reeds bestaande module uit het Flexicap-project. Deze module verwerkt automatisch alle relevante parameters die nodig zijn om correcte facturen op te stellen, rekening houdend met het gekozen contracttype, de netbeheerder en het jaar waarvoor marktprijzen gelden.

Het is belangrijk te benadrukken dat er niet zoiets bestaat als één vast dynamisch tarief. Verschillende contractvarianten bestaan, afhankelijk van onder andere de leverancier, het gekozen prijsmodel en bijkomende kosten [11]. Binnen deze studie is daarom expliciet gekozen voor één representatief dynamisch contract, zodat resultaten vergeleken kunnen worden met een variabel contract.

Daarnaast moet ook een netbeheerder worden opgegeven, aangezien distributiekosten, heffingen en vaste bijdragen variëren per regio [11]. Voor dit onderzoek werd gekozen voor Fluvius als representatieve netbeheerder. Tot slot is ook het jaartal van belang: hier werd 2023 gekozen, omdat de dynamische marktprijzen voor dat jaar vol-

3 Algoritmes

ledig beschikbaar zijn en representatief worden geacht voor hedendaagse marktomstandigheden. Voor latere jaren zijn nog niet alle data vrijgegeven.

Zodra het gekozen contract en het bijbehorende tariefobject volledig zijn vastgelegd, worden de dynamische elektriciteitsprijzen opgehaald. Deze zijn gebaseerd op de Belpex day-ahead marktprijzen, vermeerderd met nettarieven, toeslagen en heffingen, zoals van toepassing bij het gekozen netgebied en contracttype [1].

Deze dynamische prijzen vormen een essentiële input voor het RHLP-algoritme. Ze stellen het algoritme in staat om batterijacties — zoals laden en ontladen — af te stemmen op de voordeligste momenten binnen de prijschommelingen van de markt. Op die manier kan het algoritme optimaal gebruikmaken van de actuele prijsinformatie om de totale energiekost te minimaliseren.

Niet alleen zijn deze prijzen belangrijk voor de sturing tijdens de optimalisatie, ze zijn ook noodzakelijk om achteraf de prestaties van de verschillende algoritmes onderling op een eerlijke manier te vergelijken. Om correcte beslissingen te nemen, heeft het RHLP-algoritme deze prijsinformatie dus op voorhand nodig.

3.2.1 Lineaire optimalisatie

Lineaire optimalisatie, ook wel lineair programmeren genoemd, is een wiskundige techniek die wordt gebruikt om een doelstelling — zoals het minimaliseren van kosten of het maximaliseren van efficiëntie — optimaal te bereiken binnen een reeks beperkingen. Zowel de doelstelling als de beperkingen worden uitgedrukt in lineaire vergelijkingen of ongelijkheden.

Deze techniek wordt veel toegepast in domeinen zoals operationeel onderzoek, logistiek en energiebeheer, waar keuzes moeten worden gemaakt binnen beperkte middelen. Een klassiek voorbeeld is het bepalen van de goedkoopste manier om grondstoffen te verdelen over verschillende productielijnen, rekening houdend met beperkingen zoals capaciteit, tijd en kosten.

In dit onderzoek werd gekozen voor een lineaire optimalisatie-aanpak omdat die toelaat om beslissingen over batterijgebruik — zoals laden, ontladen of niets doen — op een transparante en efficiënte manier te plannen op basis van voorspellingen. Lineaire modellen zijn eenvoudig te implementeren, goed reproduceerbaar en vereisen relatief weinig rekenkracht, wat ze bijzonder geschikt maakt voor toepassingen met vaste planningshorizonnen en deterministische inputdata.

3 Algoritmes

Een alternatieve methode die ook overwogen werd, is Model Predictive Control (MPC). MPC is vooral interessant in situaties waar real-time bijsturing op basis van live data mogelijk of wenselijk is. Aangezien dat in deze studie niet het geval is, werd bewust geopteerd voor een statische lineaire benadering.

3.2.2 Implementatie van Rolling Horizon Lineaire Programmatie

De gekozen optimalisatiestructuur in dit onderzoek is gebaseerd op Rolling Horizon Lineaire Programmatie (RHLP). Deze aanpak combineert klassieke lineaire optimalisatie met een schuivend tijdsvenster. Op elk moment wordt een optimalisatie uitgevoerd over een vast toekomstinterval — bijvoorbeeld twee dagen — op basis van voorspelde verbruiks- en prijsdata. Vervolgens wordt alleen de beslissing voor het eerstvolgende kwartier daadwerkelijk toegepast.

Daarna schuift het tijdsvenster één stap op, en wordt het proces herhaald met de nieuwe, verschoven inputdata. Binnen elk venster worden de voorspellingen als vast (deterministisch) beschouwd, en gebeurt de optimalisatie off-line. Er is dus geen bijsturing binnen een venster, enkel een herberekening bij het begin van elk nieuw venster.

Deze aanpak biedt het voordeel dat ze anticiperend gedrag mogelijk maakt op basis van bekende voorspellingen, zonder de complexiteit van real-time dataverwerking of heroptimalisatie op elk moment. RHLP vormt daardoor een evenwicht tussen praktische toepasbaarheid en toekomstgericht sturen.

Vergelijkbare algoritmische benaderingen zijn in de recente literatuur onderzocht in de context van dynamische elektriciteitsprijzen en batterijoptimalisatie. In [12] wordt een optimalisatiemodel voorgesteld voor elektriciteitsleveranciers dat inspeelt op prijsgevoelige vraag via rolling horizon-technieken. Studie [13] toont hoe spotmarktprijzen benut kunnen worden in lokale energiemarkten om de terugverdientijd van batterij-investeringen aanzienlijk te verkorten via prijsgevoelige sturing. Deze publicaties illustreren het academisch belang van dergelijke prijsgebaseerde optimalisatiemethoden in zowel huishoudelijke als industriële toepassingen.

De toepassing van RHLP in deze masterproef sluit dan ook aan bij actuele academische ontwikkelingen rond voorspellingsgestuurde energiesturing binnen dynamische markten.

3 Algoritmes

Verwantschap met Model Predictive Control (MPC)

De structuur van RHLP vertoont sterke gelijkenissen met die van Model Predictive Control (MPC). Beide technieken maken gebruik van een schuivend tijdsvenster waarin een optimalisatie wordt uitgevoerd, en voeren slechts de eerste beslissingsstap uit. Daarna wordt het venster verschoven en het proces herhaald.

Het belangrijkste verschil is dat MPC typisch wordt toegepast in een real-time context, waarbij bij elke stap gebruik wordt gemaakt van actuele metingen om het systeem dynamisch bij te sturen. Bij RHLP daarentegen gebeurt de optimalisatie volledig off-line, op basis van deterministische input die bij het begin van het venster vastligt.

Hoewel RHLP eenvoudiger is en minder rekenkracht vereist, biedt MPC theoretische voordelen in situaties met hoge onzekerheid of sterk fluctuerende omstandigheden. In toekomstige toepassingen — bijvoorbeeld in combinatie met live data van slimme meters of realtime marktprijzen — zou het waardevol zijn om het huidige algoritme uit te breiden tot een volwaardige MPC-algoritme. Op die manier kan robuuster en adaptiever worden ingespeeld op afwijkingen tussen voorspellingen en realiteit.

Tabel 3.1: Vergelijking tussen RHLP en Model Predictive Control (MPC)

Kenmerk	RHLP	MPC
Structuur	Rolling horizon over vaste toekomsthorizon	Rolling horizon over vaste toekomsthorizon
Optimalisatiemethode	Lineaire programmering (LP)	Kan lineair of niet-lineair zijn
Beslissingsstrategie	Enkel eerste stap van het venster wordt uitgevoerd	Enkel eerste stap van het venster wordt uitgevoerd
Inputdata	Voorspellingen (deterministisch, vast per venster)	Voorspellingen aangevuld met real-time meetdata
Heroptimalisatie	Off-line, per verschuivend venster	Real-time, bij elk nieuw meetmoment
Complexiteit	Laag, computationeel efficiënt	Hoger, vereist snellere rekentijd en data-infrastructuur
Toepassing in dit onderzoek	Simulaties en analyse met voorspelde verbruiks- en prijsdata	Niet toegepast, maar geschikt voor uitbreiding in real-time toepassingen

3.2.3 Implementatie van lineaire optimalisatie

Lineaire optimalisatie, of lineair programmeren, kan in Python worden uitgevoerd met behulp van de `linprog`-functie uit het pakket `scipy.optimize`. Het proces verloopt volgens enkele vaste stappen:

1. Formuleren van de doelfunctie:

Dit is de vergelijking die je wilt optimaliseren (minimaliseren of maximaliseren). Bijvoorbeeld: het minimaliseren van de totale kosten van energie-import. In een programmeercontext wordt deze functie voorgesteld als een vector die de coëfficiënten bevat van alle variabelen die meespelen in de optimalisatie.

2. Opstellen van de constraints:

Constraints zijn de beperkingen die gelden binnen het probleem. Deze worden in twee soorten onderverdeeld:

- **Gelijkheid constraints (A_{eq} en b_{eq}):** Deze zorgen ervoor dat bepaalde voorwaarden exact kloppen, zoals een energiebalans die altijd in evenwicht moet zijn.
- **Ongelijkheid constraints (A_{ub} en b_{ub}):** Deze leggen limieten op, bijvoorbeeld dat de batterij nooit meer mag ontladen dan haar maximale vermogen.

3. Optimalisatie uitvoeren:

Nadat de doelfunctie en constraints zijn opgesteld, wordt de optimalisatie uitgevoerd door de `linprog`-functie aan te roepen. Deze functie zoekt de optimale waarden van alle variabelen die samen het doel bereiken binnen de opgelegde beperkingen. Het resultaat bevat de geoptimaliseerde waarden voor elke variabele in het probleem.

Doelfunctie

In het RHLP-algoritme worden deze principes toegepast om het laad- en ontladgedrag van een batterij te optimaliseren binnen een rolling horizon van bijvoorbeeld twee dagen. De doelstelling is om zowel de energieafnamekosten als de netkosten te minimaliseren. De energieafnamekosten worden beperkt door op strategische momenten elektriciteit van en naar het net uit te wisselen. Tegelijk worden de netkosten — met inbegrip van het capaciteitstarief — verlaagd door pieken in het kwartierverbruik actief te vermijden.

3 Algoritmes

De doelfunctie wordt opgebouwd als een vector die per tijdstap bestaat uit verschillende componenten die theoretisch kunnen worden geoptimaliseerd:

- Netimportprijzen,
- Netexportprijzen,
- Peak shaving met drempel,
- *Laadstroom*,
- *Ontlaadstroom*,
- *State of charge (batterijstatus)*,

In de huidige implementatie worden enkel de eerste drie componenten effectief opgenomen in de optimalisatie: netimportprijzen, netexportprijzen en peak shaving met drempel. Netimport en netexport bepalen het merendeel van de kosten en baten in het model, terwijl de piekcomponent een bijkomend strafmechanisme introduceert voor kwartierverbruiken boven een ingestelde drempelwaarde.

De waarden voor netimport en netexport zijn gebaseerd op de werkelijke marktprijzen. Deze prijzen worden rechtstreeks als coëfficiënten in de doelfunctie opgenomen: een positieve importprijs verhoogt de totale kost, terwijl een negatieve exportprijs een besparing oplevert. Door de structurele prijsverhouding — waarbij exportvergoedingen vrijwel altijd lager liggen dan afnameprijzen — ontstaat er binnen het model automatisch een voorkeur om netimport te vermijden in plaats van elektriciteit te exporteren. Dit stimuleert het algoritme om zoveel mogelijk lokaal opgewekte energie zelf te verbruiken, wat overeenkomt met de economische realiteit.

De overige variabelen — aangeduid in cursief — werden wel geïnitieerd in de code (bijvoorbeeld met `np.zeros()`) om het model technisch correct te laten functioneren of met het oog op toekomstige uitbreidingen, maar spelen momenteel geen rol in de optimalisatiedoelstelling of besluitvorming.

Voor elke tijdstap in het horizonvenster worden de bijbehorende importprijzen en exportvergoedingen opgenomen in de doelfunctie. Hierdoor wordt het model gestimuleerd om te laden tijdens goedkopere momenten en te ontladen of exporteren tijdens duurdere periodes.

3 Algoritmes

Constraints

De constraints in dit programma volgen de fysieke en praktische beperkingen van het systeem:

- **Energiebalans constraint:** garandeert dat op elk moment de som van PV-opwekking, netimport en batterijontlading gelijk is aan de totale vraag plus de export en het laden van de batterij.
- **SoC (state of charge) constraint:** houdt de opvolging van de laadstatus van de batterij bij over de tijd, met verliesvereffening door laad- en onlaadefficiëntie.
- **Laad- en onlaadlimieten:** zorgen ervoor dat de batterij niet sneller kan laden of ontladen dan technisch toegestaan.
- **Capaciteitslimieten:** zorgen ervoor dat de batterij nooit boven haar maximale capaciteit wordt geladen.
- **Piekbependingen:** leggen op dat het netimportvermogen per tijdstap beperkt wordt om pieken in het verbruik af te vlakken.

Elke constraint wordt als een rij in de matrices A_{eq} of A_{ub} gedefinieerd, samen met de bijhorende rechterkant in respectievelijk b_{eq} of b_{ub} . Door deze gestructureerde opbouw kan het algoritme voor elke tijdstap optimaal bepalen hoeveel moet worden geladen, ontladen, geïmporteerd of geëxporteerd, binnen de opgelegde technische en economische beperkingen.

3.2.4 Wiskundige formulering

De kern van de optimalisatie bestaat uit het minimaliseren van de totale energiekost, waarbij zowel de dynamische elektriciteitsprijzen als piekverbruik expliciet worden meegenomen in de berekening. De doelfunctie die wordt geminimaliseerd, is als volgt opgesteld:

$$\min \sum_{t=1}^N (C_{import,t} \cdot G_{import,t} - C_{export,t} \cdot G_{export,t}) + P_{penalty} \cdot E \quad (3.1)$$

Hierbij stelt $C_{import,t}$ de prijs voor van elektriciteitsimport per kwartier t en $C_{export,t}$ de vergoeding voor export. De variabelen $G_{import,t}$ en $G_{export,t}$ vertegenwoordigen respectievelijk de hoeveelheid geïmporteerde en geëxporteerde elektriciteit op tijdstip t . Daar-

3 Algoritmes

naast wordt een zware boete P_{penalty} toegekend aan de overschrijding E van de vooraf vastgestelde piekimportdrempel, zodat het algoritme actief piekbelasting probeert te vermijden.

Om ervoor te zorgen dat het systeem fysisch correct werkt, worden verschillende constraints opgelegd. Allereerst is er de energiebalans, die op elk moment moet gelden:

$$PV_t + G_{\text{import},t} + D_t = L_t + G_{\text{export},t} + C_t \quad (3.2)$$

In deze vergelijking stelt PV_t de zonneproductie voor, L_t de elektriciteitsvraag, C_t het laadvermogen van de batterij en D_t het ontladvermogen. Deze vergelijking garandeert dat de som van alle inkomende energiestromen (PV, netimport, ontlading) exact gelijk is aan de som van alle uitgaande stromen (vraag, netexport, laden).

Daarnaast wordt de batterijstaat (state of charge, SoC) dynamisch bijgehouden over het horizonvenster. Voor elk tijdstip t geldt:

$$SoC_t = SoC_{t-1} + \eta_{\text{ch}} \cdot C_t - \frac{D_t}{\eta_{\text{dis}}} \quad (3.3)$$

waarbij η_{ch} en η_{dis} respectievelijk de laad- en ontladefficiëntie voorstellen. Deze vergelijking houdt rekening met rendementsverliezen en zorgt ervoor dat het algoritme een realistisch model van de batterijstaat hanteert.

Om te vermijden dat de batterij fysiek onmogelijke acties uitvoert, worden er capaciteitsbeperkingen opgelegd:

$$0 \leq C_t \leq C_{\text{max}} \quad (3.4)$$

$$0 \leq D_t \leq D_{\text{max}} \quad (3.5)$$

$$0 \leq SoC_t \leq SoC_{\text{max}} \quad (3.6)$$

Hierbij zijn C_{max} , D_{max} en SoC_{max} respectievelijk het maximale laadvermogen, maximale ontladvermogen en de maximale batterijkapaciteit. Deze beperkingen worden geprogrammeerd in de ongelijkheidsmatrices (A_{ub} en b_{ub}) in het lineaire model.

Tot slot is er de piekbeperking, die ervoor zorgt dat de netimport op elk moment beperkt blijft tot een vooraf ingestelde drempel P_{peak} , waarbij een eventuele overschrijding E zwaar bestraft wordt:

3 Algoritmes

$$G_{\text{import},t} \leq P_{\text{peak}} + E \quad (3.7)$$


In de implementatie wordt elke constraint vertaald naar een rij in de matrices A_{eq} (voor gelijkheidsrestricties) en A_{ub} (voor ongelijkheidsrestricties), met bijhorende rechterkanten b_{eq} en b_{ub} . De doelfunctie wordt opgebouwd als een vector waarin elke variabele het juiste gewicht krijgt toegekend op basis van de actuele marktprijzen en boetebedragen. Vervolgens wordt de `linprog`-functie van de SciPy-bibliotheek aangeroepen om het optimalisatieprobleem op te lossen.

Dankzij deze mathematische opbouw bepaalt het algoritme automatisch de meest kostenefficiënte laad- en ontladstrategie voor elk moment, rekening houdend met zowel technische beperkingen als economische prikkels. Omdat het probleem lineair is, garandeert deze aanpak bovendien het globale optimum binnen de opgelegde randvoorwaarden — niet enkel een lokaal optimum zoals bij heuristische methoden vaak het geval is.

- Het definiëren van de doelfunctie die de netimportkosten minimaliseert, met extra straf voor piekoverschrijdingen;
- Het toevoegen van variabelen per kwartier: laden, ontladen, SoC, import/export en piekoverschrijdingen;
- Het opstellen van constraints: energiebalans, SoC-update, laad- en ontladlimieten, batterijcapaciteit en piekbeperkingen.

De optimalisatie gebeurt met behulp van `scipy.optimize.linprog`. Indien succesvol, worden de resultaten voor het eerste kwartier geëxtraheerd en opgeslagen. Bij falen wordt een foutmelding gelogd.

3 Algoritmes



Figuur 3.2: Schematisch overzicht van het Rolling Horizon Linear Programming (RHLP)-algoritme

3 Algoritmes

In Figuur 3.2 is het volledige proces van het RHLP-algoritme schematisch weergegeven. Het algoritme start met het inladen van alle nodige gegevens, en doorloopt vervolgens per kwartier een rolling horizon-venster waarin een optimalisatieprobleem wordt opgesteld en opgelost.

Een belangrijk element in dit proces is het opstellen van de verbruiksreeks: voor het eerste kwartier wordt de werkelijke vraagwaarde gebruikt, terwijl voor de rest van het venster voorspellingen toegepast worden. Deze hybride aanpak verhoogt de nauwkeurigheid van de eerste beslissing, zonder afhankelijk te zijn van onstabiele kortetermijnvoorspellingen. De methode is daardoor uitermate geschikt voor off-line simulaties en analyse.

4

Berekening en keuze van parameters

In dit hoofdstuk worden de parameters besproken die essentieel zijn voor het opzetten van een realistische simulatie. Het gaat hierbij om zowel de berekening als de verantwoording van de gekozen waarden.

Voor elke gebruiker zijn enkel verbruiksdata beschikbaar voor de jaren 2014 tot en met 2016. De gegevens van 2014 en 2015 worden gebruikt om het voorspellingsmodel te trainen, terwijl de data van 2016 dienen voor evaluatie en simulatie. Omdat parameters zoals de batterijcapaciteit en de grootte van de PV-installatie niet rechtstreeks beschikbaar zijn, moeten deze parameters worden afgeleid of geschat. In dit hoofdstuk wordt toegelicht hoe deze parameters bepaald worden.

De drie belangrijkste gebruikersspecifieke parameters zijn:

- de grootte van de PV-installatie,
- de batterijcapaciteit,
- en de peakshaving drempel.

Naast deze parameters speelt ook het type energiecontract een cruciale rol, aangezien dit bepaalt op welke wijze de energiekosten worden berekend.

4.1 PV-installatie

Aannames:

- Er wordt gewerkt met een 1:1 dimensionering (PV-vermogen in kWp $\approx$ batterijcapaciteit in kWh).
- De installatie bestaat voor 50% uit west- en 50% uit oostgerichte panelen.

4 Berekening en keuze van parameters

1:1 dimensionering

De opbrengstprofielen worden eerst genormaliseerd door elke waarde te delen door de som van alle waarden. Vervolgens wordt dit profiel geschaald zodat de totale jaarlijkse opbrengst gelijk is aan het gemiddelde jaarverbruik van 2014 en 2015. Op die manier wordt de opbrengst aangepast aan het werkelijke verbruik van de verbruiker, zonder daarbij gebruik te maken van informatie uit het te simuleren jaar 2016. Dit draagt bij tot de realiteitsgehalte van de simulatie.

Een 1:1 dimensionering wordt gekozen omdat dit een praktisch evenwicht biedt tussen productie en opslagcapaciteit. Hierdoor kan een groot deel van de dagelijkse zonne-productie tijdelijk worden opgeslagen en later lokaal verbruikt worden, wat de zelfconsumptie verhoogt. Dit principe wordt ook ondersteund door technische richtlijnen van de International Energy Agency [14] en de cursusnota's van de Universiteit Gent [15].

Oost-West

De mix van west- en oostgerichte panelen wordt gerealiseerd door voor elk tijdstip het gemiddelde te nemen van de afzonderlijke opbrengsten van west- en oostgerichte opstellingen.

Deze keuze zorgt voor een meer gespreide energieproductie over de dag. Terwijl zuidgerichte panelen een uitgesproken piek rond de middag produceren, genereren oost-west georiënteerde systemen productie in de ochtend en de late namiddag. Hierdoor is de overlap met het dagelijkse verbruiksprofiel groter en wordt de netinjectie beperkt. Bovendien biedt deze opstelling voordelen op vlak van dakbenutting, minder onderlinge schaduw en betere benutting van omvormers [15], [16].

4.2 Batterijcapaciteit

De batterijcapaciteit wordt bepaald op basis van de grootte van de PV-installatie. Bij een 1:1-dimensionering wordt uitgegaan van een gelijke verhouding tussen het piekvermogen van de PV-installatie (in kWp) en de bruikbare opslagcapaciteit van de batterij (in kWh). Waarbij *DoD* staat voor Depth of Discharge.

$$\text{nominale capaciteit} = \frac{\text{PV-piekvermogen}}{\text{DoD}} \quad (4.1)$$

4 Berekening en keuze van parameters

4.3 Peakshavingdrempel

Om de optimale drempel voor peak shaving te bepalen, zijn verschillende methoden mogelijk. Een veelgebruikte benadering is het analyseren van de Load Duration Curve (LDC), die een geordende weergave biedt van het vermogensverbruik over een bepaalde periode. Deze curve toont hoeveel procent van de tijd een bepaald vermogensniveau wordt overschreden, waardoor pieken in het verbruik visueel duidelijk worden en de impact van peak shaving eenvoudig geëvalueerd kan worden.

Een specifieke methode binnen deze benadering is het bepalen van de drempel op basis van het omslagpunt in de tweede afgeleide van de LDC-curve. Door het nulpunt of het sterkste negatieve punt van de tweede afgeleide te identificeren, kan men het omslagpunt detecteren waar de curve overgaat van een steile daling (intense piekbelasting) naar een vlakker verloop (meer gemiddeld verbruik). Dit punt fungeert als een goed benaderingspunt voor een dynamisch afgeleide peakshavingdrempel. Deze werkwijze wordt onder meer toegepast in een studie waarin de tweede afgeleide van de LDC wordt gebruikt om het omslagpunt te identificeren voor het optimaliseren van load shaping en peak shaving [17].

Een alternatieve methode is het gebruik van optimalisatie-algoritmen die historische verbruiksgegevens analyseren om een optimale shave level te bepalen. Deze aanpak maakt gebruik van statistische en optimalisatietechnieken om de drempel te bepalen die het energieverbruik tijdens piekperiodes minimaliseert, rekening houdend met de capaciteit van energieopslagsystemen en andere operationele beperkingen [18].

In deze studie is gekozen voor de methode gebaseerd op de tweede afgeleide van de LDC vanwege de reproduceerbaarheid en de geschiktheid voor analyse op basis van historische verbruiksgegevens. Deze aanpak vereist geen real-time data of complexe communicatiesystemen, waardoor het een praktische en robuuste methode is voor het bepalen van de peakshavingdrempel in diverse toepassingen.

4.4 Type contract

In wat volgt worden twee types energiecontracten in beschouwing genomen: een variabel contract en een dynamisch contract. Aangezien het basisalgoritme – dat als referentiepunt dient – geen rekening houdt met dynamische prijzen, wordt hiervoor meestal een variabel contract gehanteerd. Het RHLP-algoritme daarentegen is speci-

4 Berekening en keuze van parameters

fiek ontworpen om te optimaliseren op basis van dynamische prijsinformatie, waardoor het gebruik van een dynamisch contract hier aangewezen is.

Het verschil in contracttype bemoeilijkt echter een directe vergelijking tussen beide algoritmes. Indien bijvoorbeeld een variabel contract gemiddeld genomen voordeliger uitvalt, kan dit ertoe leiden dat het prestatieverschil deels toe te schrijven is aan het contracttype en niet uitsluitend aan het algoritme zelf. Om een eerlijke vergelijking mogelijk te maken, worden de kosten van beide algoritmes in sommige gevallen ook berekend onder eenzelfde contracttype. Zo kunnen de effecten van het onderliggende contract worden geneutraliseerd en blijft de focus gericht op de prestatie van de algoritmes zelf.

4.4.1 Variabel contract

Bij een variabel contract verandert de energieprijs periodiek (bijvoorbeeld maandelijks of per kwartaal). De prijs is doorgaans gebaseerd op een marktindex, zoals de gemiddelde Belpex-prijs of op termijncontracten (futures). In het geval van futures kent de gebruiker de prijs op voorhand voor de afgesproken periode. Als het contract echter gebaseerd is op het Belpex-gemiddelde, dan is de exacte prijs pas achteraf gekend. Beide varianten bestaan, maar mogen niet met elkaar worden verward of gemengd.

4.4.2 Dynamisch contract

Bij een dynamisch contract volgt de energieprijs rechtstreeks de marktprijs op de Belpex-beurs. De prijzen worden vastgesteld via de zogenoemde *day-aheadmarkt*, waarbij leveranciers en afnemers één dag op voorhand hun energie verhandelen voor elk uur van de volgende dag. Daardoor zijn de prijzen doorgaans tussen 12 en 36 uur op voorhand gekend. Deze aanpak laat toe om op korte termijn flexibel in te spelen op prijsfluctuaties. De gebruiker betaalt dus exact de uurprijs (of kwartierprijs, in het geval van kwartiermeting) zoals die op de markt zijn bepaald, vaak aangevuld met een beperkte marge. Dit type contract vereist actieve opvolging of een geautomatiseerde sturing om optimaal voordeel te halen uit de prijsschommelingen [1], [11].

5

Resultaten

Dit hoofdstuk presenteert en analyseert de resultaten van de uitgevoerde simulaties en experimenten. De prestaties van het basisalgoritme en het Rolling Horizon Linear Programming (RHLP) algoritme worden onder uiteenlopende omstandigheden vergeleken. Daarbij wordt niet alleen gekeken naar algemene kostenbesparing, maar ook naar de impact van belangrijke parameters zoals batterijcapaciteit, contracttype en de kwaliteit van de verbruiksvoorspelling. Verschillende verbruikersprofielen worden bestudeerd om te beoordelen hoe robuust en reproduceerbaar de algoritmes zijn in realistische situaties. Dit hoofdstuk biedt zo een uitgebreide evaluatie van de sterke en zwakke punten van beide algoritmes, met het oog op hun praktische toepasbaarheid.

De weergegeven percentages in deze sectie drukken de gerealiseerde winst uit. Een positieve waarde duidt op een kostenreductie, met andere woorden: het resultaat is goedkoper ten opzichte van de referentie. Deze keuze werd bewust gemaakt om de interpretatie van de figuren en correlatiecoëfficiënten te vereenvoudigen. Door deze benadering komt een stijgend percentage overeen met een verbeterde prestatie, wat de intuïtieve leesbaarheid van de resultaten ten goede komt.

Om goed te kunnen vergelijken worden doorgaans dezelfde parameters gekozen. Wanneer er voor een bepaalde test een parameter verandert, wordt deze in tabelvorm weergegeven. Als een parameter niet vermeld staat, heeft deze onderstaande standaardwaarde. De twee algoritmes worden op verschillende verbruiksprofielen getest, in Bijlage A staat hiervan een overzicht.

5 Resultaten

Tabel 5.1: Instellingen van de standaardparameters

Parameters	Basis algoritme	RHLP algoritme
Verbruiker	Verbruiker 12	Verbruiker 12
Contract	Variabel	Dynamisch
Voorspelling	n/a	XGBoost
Batterijcapaciteit (kWh)	150	150
Peak shaving threshold (kW)	20	20
Initiële SoC	50%	50%
Periode	1 jaar	1 jaar
Efficiëntie	90%	90%
c-rate	1	1

5.1 Vergelijking tussen het basisalgoritme en het RHLP-algoritme


De eerste en belangrijkste vergelijking in deze studie is die tussen het basisalgoritme en het RHLP-algoritme, elk geëvalueerd onder hun meest realistische gebruikswaarden. In de praktijk zou het basisalgoritme waarschijnlijk gecombineerd worden met een klassiek variabel contract — zonder toegang tot kortetermijnprijsinformatie of geavanceerde voorspellingen — terwijl het RHLP-algoritme net ontwikkeld is om optimaal te kunnen functioneren in combinatie met een dynamisch elektriciteitscontract en voorspelde verbruiksreeksen.

In wat volgt worden beide algoritmes geëvalueerd onder hun respectieve ‘optimale’ condities voor **verbruiker 12**: het basisalgoritme onder een variabel tarief, en het RHLP-algoritme onder een dynamisch tarief, met voorspelling van verbruik. Deze setting benadert het best hoe de algoritmes in werkelijkheid zouden worden ingezet. Het resultaat is dus niet louter een theoretische vergelijking, maar een inschatting van de effectieve meerwaarde die het RHLP-algoritme in een echte toepassing voor deze gebruiker kan opleveren.

5 Resultaten

Tabel 5.2: Vergelijking van prestaties onder realistische contractomstandigheden

Algoritme	Basisalgoritme	RHLP-algoritme
Contracttype	Variabel	Dynamisch
Energiekost afname	4679,10	3663,05
Injectievergoeding	2628,03	2111,83
Netkost totaal	4447,52	3644,15
Heffingen totaal	1480,18	1343,49
Onbalansvergoeding	0,00	0,00
Totaal tarief	7978,77	6980,17
Winst [%]	–	12,57%



Figuur 5.1: Vergelijking van kostencomponenten tussen het basisalgoritme en het RHLP-algoritme

Zoals weergegeven in Tabel 5.2 en visueel ondersteund door Figuur 5.1, presteert het RHLP-algoritme in combinatie met realistische verbruiksvoorspellingen en een dynamisch tarief duidelijk beter dan het basisalgoritme onder een variabel contract. De totale energiefactuur daalt van 7978,77 euro naar 6980,17 euro, wat neerkomt op een besparing van 12,6%.

5 Resultaten


Deze besparing is het resultaat van structurele verbeteringen in meerdere kostencomponenten:

- **Energiekost voor afname:** daalt met meer dan 1000 euro. Dankzij de prijsinformatie kan het RHLP-algoritme strategisch laden tijdens goedkope kwartieren. Het basisalgoritme mist dit voordeel volledig.
- **Netkost:** daalt met ongeveer 800 euro. De betere spreiding van de belasting door het RHLP-algoritme leidt tot minder pieken en een efficiënter gebruik van het net.
- **Injectievergoeding:** ligt lager bij RHLP, wat positief is. Het algoritme weet meer lokaal opgewekte energie zelf te gebruiken in plaats van te injecteren — een teken van verhoogde zelfconsumptie.
- **Heffingen:** zijn licht gedaald, als gevolg van lagere jaarafname en efficiënter gebruik van het systeem.

Deze gecombineerde winst resulteert in een overtuigend totaalvoordeel van meer dan 12 procent ten opzichte van het basisalgoritme. Het toont aan dat het inzetten van een voorspellingsgestuurd algoritme zoals RHLP, gekoppeld aan een dynamisch contract, niet alleen theoretisch beter presteert maar ook praktisch een tastbare financiële meerwaarde biedt.

Om de generaliseerbaarheid van deze bevindingen te toetsen, werd dezelfde vergelijking uitgevoerd voor vijf extra industriële verbruikers. Figuur 5.2 toont de procentuele kostenbesparing die het RHLP-algoritme (onder dynamisch contract) realiseerde ten opzichte van het basisalgoritme (onder variabel contract) per verbruiker.

5 Resultaten



Figuur 5.2: Procentuele kostenreductie van het RHLP-algoritme t.o.v. het basisalgoritme per verbruiker (realistische contracten)

De resultaten tonen aan dat het RHLP-algoritme bij vier van de zes verbruikers een besparing realiseert, met een winst tot ruim 14%. Voor twee gebruikers (7 & 15) resulteerde het gebruik van het RHLP-algoritme in een hogere kost. Dit wijst erop dat de winstgevendheid van het RHLP-model mede afhangt van het verbruiksprofiel en de mate waarin dit profiel gunstig samenvalt met prijsschommelingen op de markt. Gemiddeld werd een besparing van **4,91%** gerealiseerd over alle zes verbruikers. Dit bevestigt dat het RHLP-algoritme onder dynamische tarieven in de meeste gevallen leidt tot tastbare financiële meerwaarde.

5.1.1 Dynamisch contract

Grote professionele verbruikers — zoals bijvoorbeeld industriële sites, datacenters of andere grootverbruikers — hebben in België in veel gevallen niet langer de keuze tussen een vast, variabel of dynamisch contract. Ze zijn verplicht om een contract met een dynamisch prijssysteem af te nemen. Volgens de VREG is een dynamisch elektriciteitscontract sinds 1 januari 2023 verplicht voor afnemers met een jaarverbruik van meer dan 100 MWh en een AMR-meter [19]. Ook Fluvius bevestigt dat alle grootverbruikers in het laagspanningsnet met AMR-meting automatisch een dynamisch contract toegewezen krijgen [20].

Tegen deze achtergrond is het bijzonder relevant om de prestaties van het RHLP-algoritme en het basisalgoritme te vergelijken onder een dynamisch contract. In onder-

5 Resultaten

staande analyse worden beide algoritmes geëvalueerd onder identieke voorwaarden, namelijk het gebruik van een dynamisch elektriciteitscontract. De vergelijking werd eerst uitgevoerd voor **verbruiker 12**, een representatief profiel met een jaarlijks verbruik boven de 100 MWh.


Tabel 5.3: Vergelijking tussen basisalgoritme en RHLP-algoritme met dynamisch contract (verbruiker 12)

Algoritme	Basisalgoritme	RHLP-algoritme
Contract	Dynamisch	Dynamisch
Energiekost afname	4746,12	3663,05
Injectievergoeding	1963,24	2111,83
Netkost totaal	4447,52	3644,15
Heffingen totaal	1480,18	1343,49
Onbalansvergoeding	0,00	0,00
Totaal tarief	8710,59	6980,17
Winst [%]	–	19,87%

Zoals uit de tabel blijkt, realiseert het RHLP-algoritme een kostenbesparing van bijna 20% ten opzichte van het basisalgoritme bij gebruik van een dynamisch contract. Deze besparing is het resultaat van strategische batterij-inzet gebaseerd op voorspellingen en prijsinformatie, in tegenstelling tot het reactieve karakter van het regelgebaseerde basisalgoritme.

Om de generaliseerbaarheid van deze bevinding te evalueren, werd dezelfde vergelijking uitgevoerd voor vijf bijkomende industriële gebruikers met uiteenlopende verbruiksprofielen. De resultaten zijn weergegeven in Figuur 5.3.

5 Resultaten



Figuur 5.3: Procentuele kostenreductie van het RHLP-algoritme t.o.v. het basisalgoritme per verbruiker (dynamisch contract)

De resultaten tonen aan dat het RHLP-algoritme systematisch betere prestaties levert dan het basisalgoritme, voor elk van de zes onderzochte industriële profielen. De relatieve besparingen variëren van 13% tot meer dan 22%, met een gemiddelde besparing van **18,73%**. Dit bevestigt dat voorspellende, prijsgevoelige batterijsturing substantiële voordelen biedt in de context van dynamische elektriciteitscontracten.

Voor grote verbruikers, waar een dynamisch contract wettelijk verplicht of standaard is, vormt het RHLP-algoritme dus geen louter theoretische optimalisatie, maar een concrete en financieel relevante strategie om de energiefactuur te verlagen.

5.1.2 Perfecte voorspelling: theoretische bovengrens

In deze sectie wordt het RHLP-algoritme geëvalueerd onder de aanname van perfecte voorspellingsinformatie. Dit scenario — waarin het werkelijke verbruik wordt gebruikt als input — vertegenwoordigt de theoretische bovengrens van wat het RHLP-algoritme maximaal kan realiseren wanneer de voorspelling perfect is. Het resultaat dient als benchmark voor de best haalbare performantie. Ter vergelijking worden ook twee referentiescenario's opgenomen. Enerzijds wordt het basisalgoritme geëvalueerd in combinatie met een klassiek variabel contract — een contractvorm die, afhankelijk van het verbruiksprofiel, voordeliger kan uitvallen dan een dynamisch contract. Anderzijds wordt het basisalgoritme toegepast onder een dynamisch contract, wat een meer realistische referentie vormt voor grotere industriële verbruikers.

5 Resultaten

Tabel 5.4: Vergelijking tussen basisalgoritme met variabel contract en RHLP-algoritme met perfecte voorspelling

Algoritme	Basisalgoritme	Basisalgoritme	RHLP-algoritme
Contract	Variabel	Dynamisch	Dynamisch
Voorspelling	n.v.t.	n.v.t.	Perfect
Energiekost afname	4679,10	4746,12	3484,51
Injectievergoeding	2628,03	1963,24	2058,12
Netkost totaal	4447,52	4447,52	4064,55
Heffingen totaal	1480,18	1480,18	1326,25
Onbalans vergoeding	0,00	0,00	0,00
Totaal tarief	7978,77	8710,59	6817,19
Winst t.o.v. basisalgoritme met variabel contract [%]	–	–	14,65%
Winst t.o.v. basisalgoritme met dynamisch contract [%]	–	–	21,74%

Uit Tabel 5.4 blijkt dat het RHLP-algoritme met perfecte voorspelling aanzienlijk beter presteert dan het basisalgoritme, ongeacht het gebruikte contracttype. De totale kost daalt met bijna 15% ten opzichte van het basisalgoritme met variabel contract, en zelfs met meer dan 21% ten opzichte van het basisalgoritme onder dynamisch contract.

Deze resultaten illustreren de theoretische bovengrens van de besparing die het RHLP-algoritme kan realiseren wanneer de voorspelling van het verbruik perfect is. Hoewel dit scenario in de praktijk onhaalbaar is, biedt het wel inzicht in het maximaal haalbare voordeel dat voorspellingsgestuurde optimalisatie kan opleveren wanneer het gebruik maakt van een perfecte voorspelling.

Tegelijk toont de vergelijking aan dat de meerwaarde van een perfecte voorspelling ten opzichte van een realistische voorspelling relatief beperkt blijft. In eerder besproken scenario's lag het verschil tussen een degelijke voorspelling en een perfecte voorspelling op slechts enkele procenten. Dit suggereert dat het streven naar foutloze voorspellingen niet strikt noodzakelijk is.

In plaats van grote inspanningen te leveren om de nauwkeurigheid van de voorspelling marginaal te verbeteren, is het zinvoller om de algoritmische aanpak zelf verder te verfijnen. Denk daarbij aan het integreren van aanvullende marktdynamieken zoals onbalansvergoedingen, of het overstappen naar een meer adaptieve sturingsmethode

5 Resultaten

zoals Model Predictive Control (MPC). Dergelijke verbeteringen hebben potentieel een grotere impact op het eindresultaat dan het minimaliseren van de voorspellingsfout tot in de perfectie.

5.1.3 Kwaliteit van de voorspelling

In de vorige secties werd aangetoond dat het RHLP-algoritme, wanneer het beschikt over perfecte informatie, aanzienlijk beter presteert dan het basisalgoritme. In de praktijk is die perfecte informatie echter niet beschikbaar, en is het algoritme aangewezen op voorspellingen van het elektriciteitsverbruik. In wat volgt wordt daarom onderzocht hoe gevoelig het RHLP-algoritme is voor de kwaliteit van deze voorspellingen.

De test wordt uitgevoerd onder een dynamisch contract, waarbij drie situaties worden vergeleken:

- **RHLP 1:** het algoritme ontvangt een nietszeggende voorspelling — een vlakke reeks op basis van het gemiddelde voorspelde verbruik;
- **RHLP 2:** het algoritme ontvangt een realistische voorspelling (zoals eerder gebruikt in de hoofdvergelijkingen);
- **RHLP 3:** het algoritme ontvangt een perfecte voorspelling, gelijk aan het werkelijke verbruik.

Op die manier kan de impact van de voorspellingsnauwkeurigheid op de prestaties van het RHLP-algoritme in kaart worden gebracht.

Tabel 5.5: Impact van de kwaliteit van de voorspelling op het RHLP-algoritme

Algoritme	RHLP 1	RHLP 2	RHLP 3
Voorspellingstype	gemiddelde	XGBoost	perfect
Energiekost afname	3632,28	3663,05	3484,51
Injectievergoeding	2107,87	2111,93	2058,12
Netkost totaal	4239,91	4191,96	4064,55
Heffingen totaal	1348,57	1343,49	1326,25
Onbalansvergoeding	0,00	0,00	0,00
Totaal tarief	7112,89	6980,17	6817,19
% Winst t.o.v. RHLP 1	—	1,87%	4,16%

Uit Tabel 5.5 blijkt dat het gebruik van een realistische voorspelling het algoritme in staat

5 Resultaten

stelt om gemiddeld 1,9% beter te presteren dan in het geval van een nietszeggende voorspelling. Bij een perfecte voorspelling stijgt dit verschil tot 4,2%. De impact van de voorspellingskwaliteit is dus duidelijk aantoonbaar, maar blijft relatief beperkt.

Dit levert een belangrijk inzicht op: zelfs wanneer het RHLP-algoritme wordt gevoed met een eenvoudige of onnauwkeurige voorspelling, blijven de prestaties opmerkelijk goed. Dat impliceert dat het algoritme ook toepasbaar is in contexten waar weinig historische data beschikbaar zijn, of waar de opbouw van een betrouwbaar voorspellingsmodel moeilijk is.

De winst die wordt geboekt door betere voorspellingen situeert zich vooral op het niveau van de netkosten. Dit komt doordat het accuraat voorspellen van piekmomenten en hun grootte het mogelijk maakt om batterijen tijdig en efficiënt in te zetten ter vermijding van hoge piekverbruiken. In dat opzicht is het correct inschatten van *wanneer* en *hoe hoog* de pieken zijn de meest bepalende factor voor verdere optimalisatie.

Daarnaast is het belangrijk om te nuanceren dat de zogenoemde 'nietszeggende' voorspelling — in de vorm van een constante reeks gebaseerd op het gemiddelde voorspelde verbruik — in werkelijkheid niet volledig zonder informatiewaarde is. Doordat het algoritme veronderstelt dat in elk kwartier een gemiddelde hoeveelheid verbruik zal optreden, anticipeert het voortdurend op een constante basisvraag. Dit leidt ertoe dat de batterij doorgaans proactief wordt opgeladen om voorbereid te zijn op die veronderstelde vraag, zelfs wanneer deze zich niet exact voordoet. In zekere zin fungeert deze aanpak als een impliciete bufferstrategie: doordat het algoritme uitgaat van een permanent aanwezig verbruiksniveau, houdt het structureel een zekere reserve aan energie beschikbaar. Hierdoor kan het onverwachte pieken vaak toch gedeeltelijk opvangen. Deze robuuste gedragsreactie verklaart waarom het RHLP-algoritme verrassend goed blijft presteren, zelfs wanneer de gebruikte voorspelling weinig dynamiek bevat.

5.2 Sensitiviteitsanalyse

5.2.1 Batterijcapaciteit

In wat volgt wordt onderzocht hoe de grootte van de batterijcapaciteit de prestaties van beide algoritmes beïnvloedt. In de vorige vergelijkingen werd de batterijcapaciteit constant gehouden op 150 kWh. In deze analyse variëren we de capaciteit van 25 kWh — wat als ondergedimensioneerd kan worden beschouwd — tot 350 kWh voor verbruiker 12, wat een duidelijk overgedimensioneerd scenario vertegenwoordigt ten opzichte van

5 Resultaten

de bijhorende PV-installatie.

Door de totale jaarlijkse energiekost uit te zetten in functie van de batterijcapaciteit kunnen we evalueren hoe gevoelig elk algoritme is voor deze parameter en in welke mate een grotere batterij nog bijdraagt aan een verdere kostenreductie.

Tabel 5.6: Parameters voor evaluatie batterijcapaciteit


Parameters	Basis algoritme	RHLP algoritme
Drempel [kW]	20	20
Contract	Variabel	Dynamisch
Initiële SoC	25	25

Tabel 5.7: Vergelijking van kosten bij verschillende batterijcapaciteiten

Batterijcapaciteit (kWh)	Basis algoritme	RHLP algoritme	% Winst
25	9495,93	9798,80	-3,19
50	9132,97	8960,69	1,89
75	8823,22	8287,80	6,07
100	8534,72	7756,00	9,12
125	8260,73	7341,82	11,12
150	7996,28	6991,93	12,56
175	7752,32	6693,19	13,65
200	7549,00	6566,98	13,02
225	7340,49	6423,39	12,49
250	7155,14	6303,27	11,91
275	6995,74	6198,43	11,39
300	7024,60	6107,39	13,04
325	7024,60	6030,32	14,17
350	6914,91	5959,52	13,83

5 Resultaten

Vergelijking van absolute kost en relatieve winst in functie van batterijcapaciteit



Figuur 5.4: Vergelijking van absolute kost en relatieve winst in functie van batterijcapaciteit

Uit de resultaten blijkt dat het basisalgoritme, ondanks zijn eenvoud, beter presteert bij kleine batterijcapaciteiten. Dit doordat het RHLP-algoritme in dit geval gedwongen wordt om te werken met dynamische prijzen, zonder over voldoende batterijcapaciteit te beschikken om deze prijsschommelingen optimaal te benutten. Bij kleine batterijvolumes ontbreekt de flexibiliteit om goedkope momenten strategisch uit te buiten en dure momenten te vermijden, wat de meerwaarde van voorspellingen beperkt.

Naarmate de batterijcapaciteit toeneemt, krijgt het RHLP-algoritme meer ruimte om zijn optimalisatiepotentieel te benutten. Het kan dan prijsverschillen en netkosten strategisch afvlakken, wat leidt tot een lagere totale energiekost. Het omslagpunt waarbij het RHLP-algoritme het basisalgoritme begint te overtreffen, situeert zich in dit geval rond de 35 à 40 kWh.

5.2.2 Resultaten voor verschillende profielen

In dit onderdeel worden de prestaties van het RHLP-algoritme geanalyseerd voor een reeks uiteenlopende gebruikersprofielen. De focus ligt op drie mogelijke verklarende factoren die de effectiviteit van het algoritme beïnvloeden: de kwaliteit van de verbruiksvoorspellingen, het tijdstip waarop verbruik plaatsvindt (met name tijdens goedkope daluren), en de structurele prijsvolatiliteit op de elektriciteitsmarkt.

5 Resultaten

Door het algoritme te evalueren onder verschillende omstandigheden en voor verschillende verbruikers, wordt getracht een beter inzicht te krijgen in de situaties waarin het RHLP-algoritme het meest rendeeft. In wat volgt worden deze factoren afzonderlijk besproken en onderbouwd met empirische resultaten.

Voorspelling

Allereerst wordt de oorspronkelijke voorspelling vervangen door een perfecte voorspelling, om na te gaan in welke mate een verhoogde voorspellingsnauwkeurigheid bijdraagt aan betere resultaten.

	RHLP met werkelijke voorspelling winst t.o.v. basis algoritme	RHLP met perfecte voorspelling winst t.o.v. basis algoritme
Verbruiker 3	14,35%	22,30%
Verbruiker 6	0,14%	4,34%
Verbruiker 7	-0,84%	4,20%
Verbruiker 12	12,52%	14,65%
Verbruiker 15	-7,05%	-1,93%
Verbruiker 43	10,36%	11,79%

Tabel 5.8: Gerealiseerde winst met werkelijke en perfecte voorspelling.


Tabel 5.8 toont dat nauwkeurigere voorspellingen resulteren in hogere besparingen met het RHLP-algoritme. Dit onderstreept het belang van voorspellingskwaliteit voor optimale prestaties.

Toch blijkt het verband tussen voorspellingsnauwkeurigheid en de gerealiseerde winst bij gebruik van een realistische voorspelling niet altijd eenduidig. In Tabel 5.9 en Figuur 5.5 wordt dit nader onderzocht. Hierin wordt per verbruiker zowel de F1-score — een maat voor de juistheid van piekdetectie — als de bijhorende winst t.o.v. het basisalgoritme weergegeven.

5 Resultaten

Verbruikers	F1-score (%)	% winst
Verbruiker 3	49,29	14,35
Verbruiker 12	50,00	12,52
Verbruiker 43	50,77	10,36
Verbruiker 15	56,05	-7,05
Verbruiker 6	58,52	0,14
Verbruiker 7	58,65	-0,84

Tabel 5.9: Overzicht van F1-score en bijhorende winst per verbruiker.



Figuur 5.5: Scatterplot van F1-score tegenover procentuele winst per verbruiker

Opmerkelijk is dat de berekende Pearson-correlatiecoëfficiënt tussen de F1-score en de gerealiseerde winst ongeveer $-0,88$ bedraagt. Dit wijst op een sterk negatief verband, waarbij een hogere voorspellingsnauwkeurigheid vaak gepaard ging met slechtere resultaten. In het bijzonder: gebruikers zoals Verbruiker 12 en Verbruiker 3, met een relatief lage F1-score, behaalden de hoogste winstpercentages. Anderzijds resulteerde een hoge F1-score bij Verbruiker 15, Verbruiker 6 en Verbruiker 7 niet in een positieve of verwachte kostenreductie.

Aangezien dit resultaat afwijkt van de theoretische verwachting — namelijk dat betere voorspellingen leiden tot betere optimalisatie — wordt aangenomen dat deze correlatie

5 Resultaten

mede beïnvloed wordt door andere onderliggende factoren. In het deel 5.2.2 wordt hier verder op ingegaan.

Tijdstip van verbruik

In deze sectie wordt onderzocht in welke mate het tijdstip van elektriciteitsverbruik een impact heeft op de prestaties van het RHLP-algoritme. Dynamische elektriciteitscontracten kennen immers sterk variërende prijzen afhankelijk van het moment van de dag en de week. Verbruik tijdens typische daluren — met name 's nachts en in het weekend — is doorgaans aanzienlijk goedkoper. In wat volgt wordt dieper ingegaan op de invloed van dergelijke verbruiksprofielen op de gerealiseerde kostenbesparing.


1. Verband bij vergelijking met basisalgoritme onder variabel contract In deze vergelijking wordt het RHLP-algoritme geëvalueerd onder een dynamisch contract, terwijl het basisalgoritme gebruikmaakt van een klassiek variabel tarief. Er wordt dan ook verwacht dat verbruiksprofielen met een hoog aandeel nacht- en weekendverbruik beter presteren, aangezien hun verbruik plaatsvindt tijdens goedkopere periodes onder het dynamisch tarief. Het waargenomen prestatieverschil is daardoor niet uitsluitend toe te schrijven aan de geavanceerde sturingslogica van het algoritme, maar vloeit voor een aanzienlijk deel voort uit de verschillen in tariefstructuur.

Tabel 5.10 en Figuur 5.6 illustreren het verband tussen het percentage verbruik tijdens nacht en weekend en de behaalde winst van het RHLP-algoritme ten opzichte van het basisalgoritme met een variabel contract.

Verbruikers	% nacht- en weekendverbruik	% winst
Verbruiker 15	21,76	-7,05
Verbruiker 6	28,99	0,14
Verbruiker 7	30,92	-0,84
Verbruiker 43	40,73	10,36
Verbruiker 12	49,67	12,52
Verbruiker 3	54,01	14,35

Tabel 5.10: Verband tussen het nacht- en weekendverbruik en de prestaties van het RHLP-algoritme (t.o.v. basisalgoritme met variabel contract).

5 Resultaten



Figuur 5.6: Scatterplot van nacht- en weekendverbruik tegenover procentuele winst (t.o.v. basisalgoritme met variabel contract).

De hoge correlatiecoëfficiënt ($r = +0,91$) bevestigt dat verbruikers met veel nacht- en weekendverbruik beter scoren. Dit voordeel is grotendeels toe te schrijven aan het prijsverschil tussen dynamische en variabele tarieven tijdens daluren.

2. Verband bij vergelijking met basisalgoritme onder dynamisch contract Omdat in de vorige vergelijking het verschil in contracttype (variabel versus dynamisch) een grote invloed had op de prestaties, wordt in wat volgt het RHLP-algoritme vergeleken met het basisalgoritme onder gelijke voorwaarden, namelijk een dynamisch contract. Op die manier kan nauwkeuriger worden ingeschat in welke mate het tijdstip van verbruik — los van het contracttype — een rol speelt in de prestaties van het algoritme.

De verwachting is dat verbruikers met veel nacht- en weekendverbruik nog steeds goed zullen presteren, aangezien de voordelen van een dynamisch tarief in deze periodes behouden blijven. Wat daarentegen wél wordt verwacht te veranderen, zijn de prestaties van verbruikers met weinig dalurenverbruik: hun resultaten zouden aanzienlijk kunnen verbeteren, omdat hun hoge verbruik op dure momenten nu ook in het basisalgoritme wordt doorgerekend aangezien deze nu gebruikmaakt van een dynamisch tarief.

5 Resultaten

Verbruikers	% nacht- en weekendverbruik	% winst
Verbruiker 15	21,76	13,54
Verbruiker 6	28,99	17,50
Verbruiker 7	30,92	16,12
Verbruiker 43	40,73	22,25
Verbruiker 12	49,67	19,87
Verbruiker 3	54,01	22,99

Tabel 5.11: Verband tussen nacht- en weekendverbruik en winst van RHLP-algoritme (t.o.v. basisalgoritme met dynamisch contract).

Verbruikers met een hoog percentage dalurenverbruik blijven goed scoren, wat consistent is met de verwachte voordelen van een dynamisch tarief.

Opvallender is echter dat de relatieve verbetering het grootst is bij gebruikers met een laag aandeel nacht- en weekendverbruik. Tabel 5.12 toont aan dat net deze groep — die in de vorige vergelijking minder goed presteerde — de grootste vooruitgang boekt wanneer ook het basisalgoritme onder een dynamisch contract wordt geëvalueerd. Dit bevestigt dat het RHLP-algoritme bijzonder goed presteert in situaties waar beide algoritmes met een dynamisch tarief werken, en dat het vooral meerwaarde biedt voor gebruikers die niet automatisch profiteren van de goedkope daluren.

Tabel 5.12 toont hoe sterk de prestaties van het RHLP-algoritme verbeteren wanneer het basisalgoritme overstapt van een variabel naar een dynamisch tarief. De winsttoename wordt hierbij weergegeven in functie van het aandeel nacht- en weekendverbruik per gebruiker.

Verbruikers	% nacht- en weekendverbruik	Winsttoename (%)
Verbruiker 15	21,76	20,59
Verbruiker 6	28,99	17,36
Verbruiker 7	30,92	16,96
Verbruiker 43	40,73	11,89
Verbruiker 12	49,67	7,35
Verbruiker 3	54,01	8,64

Tabel 5.12: Toename in winst van het RHLP-algoritme bij overstap van variabel naar dynamisch contract.

5 Resultaten

Terugkoppeling naar de voorspellingscorrelatie


Eerder werd aangetoond dat verbruikers met een hoog aandeel nacht- en weekendverbruik duidelijk beter presteerden wanneer het RHLP-algoritme (onder een dynamisch contract) vergeleken werd met het basisalgoritme (onder een variabel contract). Deze betere prestaties zijn grotendeels toe te schrijven aan de aard van de contracten: dynamische tarieven bieden aanzienlijke voordelen voor gebruikers die vooral tijdens goedkopere daluren verbruiken.

Toch verklaart dit niet waarom er een sterke negatieve correlatie werd vastgesteld tussen de voorspellingsnauwkeurigheid (gemeten via de F1-score) en de gerealiseerde winst. Wat verder onderzoek uitwijst, is dat het net het aandeel nacht- en weekendverbruik is dat deze lagere voorspelnaauwkeurigheid veroorzaakt.


In de sectie over voorspellingen werd reeds aangetoond dat de `werkdag`-feature — een binaire indicator die aangeeft of een dag een werkdag is — één van de belangrijkste inputvariabelen is in het XGBoost-model (zie Figuur 2.3). Deze variabele is zeer informatief voor verbruikers met een klassiek werkweekpatroon, waarbij het energieverbruik sterk verschilt tussen weekdays en weekends. Voor gebruikers die ook tijdens het weekend of 's nachts veel verbruiken, zoals gebruiker 3, biedt deze binaire scheiding echter minder extra voorspellende kracht. Het gevolg is dat de voorspellingen voor dit type gebruiker minder accuraat zijn.

Figuur 5.8 toont bijvoorbeeld dat voor gebruiker 15 — een typische werkweekgebruiker — de `werkdag`-indicator domineert in de feature importance. Bij gebruiker 3 (Figuur 5.7) is dat niet het geval: hier worden cyclische tijdskenmerken belangrijker, omdat het model niet kan vertrouwen op eenvoudige werkdag/weekend-classificatie.

5 Resultaten



Figuur 5.7: Feature importance in het XGBoost-model voor verbruiker 3 (hoog week-endverbruik)



Figuur 5.8: Feature importance in het XGBoost-model voor verbruiker 15 (laag week-endverbruik)

Het verband tussen lagere F1-score en hogere winst is dus deels te verklaren door deze samenvallende eigenschappen: veel nacht- en weekendverbruik zorgt voor een moeilijker voorspelbaar patroon, maar creëert tegelijk een gunstige omgeving voor het RHLP-algoritme en zijn dynamisch contract.


5 Resultaten

5.2.3 Invloed van verschillende marktprijzen

In dit onderdeel wordt onderzocht hoe de prestaties van het RHLP-algoritme variëren over verschillende jaren, in functie van de marktprijsomstandigheden. De analyse focust specifiek op verbruiker 12, waarbij het basisalgoritme geëvalueerd wordt onder een variabel elektriciteitscontract en het RHLP-algoritme onder een dynamisch contract. Aangezien het RHLP-algoritme ontworpen is om actief te optimaliseren op basis van prijsschommelingen, wordt verwacht dat jaren met meer variabiliteit in de marktprijzen een groter kostenvoordeel opleveren. Door de resultaten per jaar te analyseren — zoals weergegeven in Tabel 5.13 en Figuur 5.9 — en deze te vergelijken met de structuur van de marktprijzen in Figuur 5.10, kan deze relatie geobjectiveerd worden.


jaartallen	Basisalgoritme	RHLP-algoritme	% Winst
2018	6735,45	6189,53	8,11
2019	6665,24	6128,25	8,06
2020	6630,55	6254,33	5,68
2021	8373,65	8691,99	-3,80
2022	9560,86	7190,06	25,42
2023	7978,77	6980,17	12,52

Tabel 5.13: Vergelijking van prestaties tussen basis algoritme en RHLP-algoritme.



Figuur 5.9: Vergelijking van totale kosten per jaar voor RHLP- en basisalgoritme

5 Resultaten



Figuur 5.10: Boxplotanalyse van de marktprijzen (Belpex $\times$ RLP) per jaar.

Analyse van de resultaten onder verschillende marktprijzen


Uit de vergelijkende analyse tussen het basisalgoritme en het RHLP-algoritme blijkt dat de prestaties van het RHLP-algoritme sterk samenhangen met de mate van prijsvariabiliteit op de elektriciteitsmarkt. De tabel met de jaarlijkse kosten toont duidelijk aan dat het RHLP-algoritme over de meeste jaren een substantiële kostendaling realiseert ten opzichte van het basisalgoritme. Vooral in 2022 en 2023 zijn de verbeteringen uitgesproken, met respectievelijk 25,42% en 12,52% lagere totale kosten.

De link met dynamische marktprijzen wordt bevestigd door de boxplotanalyse van de Belpex-prijzen per jaar. In deze boxplot is te zien dat de prijsvariabiliteit in 2022 uitzonderlijk hoog was, gekenmerkt door een brede spreiding van de marktprijzen en een significante aanwezigheid van extreme uitschieters. Dit creëert een omgeving waarin een algoritme dat actief optimaliseert op basis van dynamische prijzen, zoals het RHLP-algoritme, maximaal kan profiteren van goedkope momenten en duur verbruik kan vermijden. De hoge winst in 2022 bevestigt dan ook dat het RHLP-algoritme effectief gebruik maakt van dynamische prijschommelingen.

In de jaren 2018 tot en met 2020, waar de boxplot aangeeft dat de prijsvariabiliteit veel beperkter was, zijn de behaalde verbeteringen van het RHLP-algoritme minder uitgesproken (tussen 5% en 8%). De beperkte spreiding van de marktprijzen in deze periode impliceert dat het voordeel van dynamisch optimaliseren kleiner is, aangezien er minder prijsverschillen zijn om op in te spelen.


5 Resultaten

Een opvallende uitzondering vormt het jaar 2021, waarin het RHLP-algoritme slechter presteert dan het basisalgoritme (-3,80%). De marktprijzen vertonen dat jaar nochtans een duidelijke toename in spreiding ten opzichte van 2018–2020, wat op het eerste gezicht tegenintuïtief lijkt. Om dit beter te begrijpen, wordt een aanvullende boxplot en grafiek opgesteld waarin de prijsvariabiliteit over telkens twee dagen wordt geanalyseerd. Voor elk venster van twee dagen wordt het verschil tussen de hoogste en laagste prijs berekend. Deze maat geeft een directer beeld van de prijschommelingen waarop het RHLP-algoritme daadwerkelijk kan inspelen binnen zijn standaard optimalisatiehorizon van twee dagen.



Figuur 5.11: Dagelijkse prijsvariabiliteit (max - min) per jaar

5 Resultaten



Figuur 5.12: Prijsvariabiliteit per 2-dagenblok in 2021

Deze analyse bracht meer nuance in de interpretatie: hoewel 2021 inderdaad een grotere spreiding vertoonde dan 2018–2020, bleef de mediaan van de prijsvariabiliteit duidelijk lager dan in 2022. Bovendien liet een gedetailleerde tijdreeksplot van de prijsvariabiliteit per 2-dagenblok zien dat de verhoogde variabiliteit in 2021 voornamelijk geconcentreerd was in de laatste maanden van het jaar. Gedurende het grootste deel van het jaar bleef de prijsvariabiliteit laag en stabiel, wat betekent dat het RHLP-algoritme het grootste deel van het jaar nauwelijks kansen kreeg om optimaal gebruik te maken van prijsschommelingen. Pas tegen het einde van het jaar begon de variabiliteit significant toe te nemen, maar tegen die tijd had het algoritme over het jaar heen al relatief weinig voordeel kunnen behalen. Dit verklaart waarom de boxplot voor 2021 weliswaar een verhoogde spreiding toont, maar de prestaties van het RHLP-algoritme toch achterblijven.

Samenvattend bevestigen deze resultaten dat het RHLP-algoritme sterker presteert naarmate de dynamische prijsschommelingen groter en beter voorspelbaar zijn binnen het standaard optimalisatievenster van twee dagen. In stabiele of licht volatiele jaren blijft het voordeel beperkt, terwijl in jaren met hoge en gestructureerde prijsvolatiliteit (zoals 2022) aanzienlijke besparingen mogelijk zijn.

Bovendien kan verwacht worden dat de volatiliteit van dynamische elektriciteitsprijzen in de toekomst verder zal toenemen, onder invloed van de toenemende integratie van hernieuwbare energiebronnen zoals zon en wind. Omdat deze bronnen sterk weersafhankelijk zijn, veroorzaken ze een minder voorspelbaar aanbod, wat zich vertaalt in

5 Resultaten

grotere prijsschommelingen op de groothandelsmarkten [21], [22]. Dit versterkt het belang van geavanceerde, adaptieve optimalisatie-algoritmen zoals het RHLP-algoritme, die flexibel kunnen inspelen op deze toenemende dynamiek in het elektriciteitslandschap.

5.3 Gedrag van het RHLP-algoritme


In de voorgaande hoofdstukken werden de prestaties van het RHLP-algoritme hoofdzakelijk beoordeeld aan de hand van globale prestatie-indicatoren, zoals kostenreductie en gemiddelde piekvervorming. In dit hoofdstuk wordt dieper ingegaan op het operationele gedrag van het algoritme op kwartierniveau. Daarbij wordt onderzocht hoe het algoritme reageert op verbruikspieken, hoe het omgaat met voorspellingsfouten, en in welke mate de batterij effectief wordt ingezet bij onverwachte fluctuaties in het verbruik.

Door concrete situaties te analyseren — zoals het optreden van pieken en de corresponderende laad- of ontlaadstrategie — wordt duidelijk hoe het RHLP-algoritme zijn beslissingen neemt en welke rol de nauwkeurigheid van de verbruiksvoorspelling daarin speelt. Deze gedragsanalyse biedt bijkomende inzichten in de sterktes en beperkingen van het algoritme, en vormt een fundament voor eventuele optimalisaties in toekomstige toepassingen.

5.3.1 Analyse van piekmomenten door voorspellingsfouten: vergelijking met perfect voorspelde situatie

Figuur 5.13 illustreert hoe het RHLP-algoritme reageert op verbruikspieken, en welke impact de nauwkeurigheid van de verbruiksvoorspelling heeft op de uitkomst. De linkerfiguur toont een situatie waarin het algoritme werkt op basis van een realistische, maar niet perfecte voorspelling. De rechterfiguur toont exact dezelfde periode, maar dan op basis van een perfecte voorspelling. De verschillen zijn opvallend en illustratief.

5 Resultaten



Figuur 5.13: Vergelijking van de batterijsturing bij XGBoost voorspelling (links) en perfecte voorspelling (rechts).

In de linkerfiguur zijn twee duidelijke piekmomenten zichtbaar in de netafname (tweede plot, blauwe lijn), rond kwartier 1780 en kwartier 1850. Beide overschrijden de normale netverbruikslimieten en wijzen op situaties waarin de batterij onvoldoende beschikbaar was om het volledige verbruik lokaal te dekken.

De eerste piek ontstaat door een gedeeltelijk onderschatte voorspelling. Het algoritme anticipeerde wel op een stijging in het verbruik, maar onderschatte de piekhoogte. Hierdoor werd de batterij ingezet, maar onvoldoende opgeladen: de SoC daalt tot een laag niveau, waarna het resterende verbruik via het net wordt ingevuld.

De tweede piek is het gevolg van een vrijwel volledig gemiste piek in het werkelijke verbruik. De voorspelling bleef vlak, waardoor het algoritme niet anticipeerde en de batterij niet vooraf werd opgeladen. Hierdoor kon de piek slechts beperkt worden opgevangen.

5 Resultaten

In beide gevallen lagen de elektriciteitsprijzen op dat moment niet bijzonder hoog, wat erop wijst dat het vermijden van netimport economisch gezien mogelijk was. De oorzaak van de piekoverschrijdingen ligt dan ook niet in de prijsoptimalisatie, maar in de onnauwkeurigheid van de voorspellingen.

De rechterfiguur toont daarentegen hoe het algoritme functioneert bij een perfecte voorspelling. In deze referentiesituatie worden de pieken volledig vermeden. De batterij wordt tijdig en accuraat opgeladen en op het juiste moment ontladen, wat resulteert in een vrijwel vlak netverbruik. Het algoritme is in staat om de volledige verbruiksvraag lokaal op te vangen.

Deze analyse bevestigt dat het RHLP-algoritme sterk afhankelijk is van de kwaliteit van de verbruiksvoorspelling. Onnauwkeurige voorspellingen leiden tot een suboptimale inzet van de batterij, met hogere netimport en bijgevolg een nadelige impact op de kostenefficiëntie, bijvoorbeeld via het capaciteitstarief.

5.3.2 Laadbeslissing op basis van dynamische prijzen

Een interessante observatie betreft het laadgedrag van de batterij vanaf kwartier 1800. Hoewel het algoritme op basis van de voorspelling weet dat zich een verbruikspiek aandient in de nabije toekomst, start het laden niet onmiddellijk zodra dit technisch mogelijk is. In plaats daarvan wacht het enkele kwartieren.

De reden voor dit uitstel wordt duidelijk bij vergelijking van de onderste grafiek (marktprijzen) met de grafiek van de SoC. Het RHLP-algoritme integreert prijsinformatie in zijn optimalisatiestrategie: omdat er op dat moment geen PV-opbrengst beschikbaar is, zou laden uitsluitend via netimport gebeuren. Het algoritme wacht daarom bewust tot de elektriciteitsprijzen dalen, waarna de batterij alsnog wordt opgeladen tegen een lagere kost.

Deze strategie toont aan dat het RHLP-algoritme niet enkel op basis van verbruiksprognoses handelt, maar ook actief economische afwegingen maakt. Zelfs bij naderende pieken kan het algoritme besluiten om het laden uit te stellen omwille van prijsoptimalisatie.

5.3.3 Vaststellingen over gedrag RHLP-algoritme

De geanalyseerde situaties tonen het volgende aan:

5 Resultaten

- Een onderschatte piek leidt tot gedeeltelijke batterijontlading, gevolgd door netimport;
- Een gemiste piek leidt tot volledige netimport zonder batterijbuffer;
- Het RHLP-algoritme maakt effectief gebruik van dynamische prijzen om de laadstrategie economisch te optimaliseren.

Het is dus essentieel dat het RHLP-algoritme wordt ondersteund door een robuust en accuraat voorspellingsmodel, en dat het beschikt over actuele prijsdata. Daarnaast kunnen aanvullende strategieën — zoals het inbouwen van een minimale SoC-buffer of het opnemen van een voorspelfoutmarge — de veerkracht van het systeem vergroten bij onzekerheid in de voorspelde vraag.

6

Conclusie

Deze masterproef onderzocht de effectiviteit van een Rolling Horizon Linear Programming (RHLP)-algoritme voor het optimaliseren van batterijsturing bij industriële verbruikers, in een context van dynamische elektriciteitsprijzen en het capaciteitstarief. De centrale onderzoeksvraag was of een voorspellingsgestuurd optimalisatie-algoritme de prestaties van een klassiek heuristisch algoritme kan overtreffen in termen van totale energiekost. De resultaten van deze studie bieden een genuanceerd inzicht in de sterktes en beperkingen van het RHLP-algoritme, op basis van een vergelijking met een klassiek heuristisch algoritme dat als benchmark werd gebruikt.

Kernbevindingen

Vergelijking met basisalgoritme onder variabel tarief In een directe vergelijking waarbij elk algoritme wordt ingezet onder zijn optimale condities — het basisalgoritme met een klassiek variabel contract en het RHLP-algoritme met een dynamisch contract — behaalde het RHLP-algoritme bij vier van de zes onderzochte verbruiksprofielen betere resultaten, met een gemiddelde kostendaling van 4,91%. Belangrijk hierbij is dat het variabel contract doorgaans stabielere en dus gunstiger is voor niet-voorspellende, reactieve algoritmes zoals het basisalgoritme. Het RHLP-algoritme werkt daarentegen onder dynamische prijssignalen, wat leidt tot grotere onzekerheid maar ook tot meer optimalisatiepotentieel. Dat het RHLP onder deze complexere omstandigheden toch een lagere energiekost realiseert, onderstreept zijn robuustheid en toegevoegde waarde.

Vergelijking met basisalgoritme onder dynamisch tarief Wanneer beide algoritmes worden ingezet onder een dynamisch contract — zoals wettelijk verplicht voor bepaalde grote industriële verbruikers — komt de meerwaarde van het RHLP-algoritme nog sterker naar voren. Gemiddeld werd in deze configuratie een kostendaling van

6 Conclusie

18,71% gerealiseerd ten opzichte van het basisalgoritme, met uitschieters tot 23%. Deze prestatieverbetering toont aan dat het RHLP-algoritme beter in staat is om in te spelen op kortetermijnschommelingen in de elektriciteitsprijs, wat leidt tot een efficiëntere inzet van de batterij.

Dalurenverbruik Ook werd aangetoond dat het aandeel nacht- en weekendverbruik — dat in deze context overeenkomt met dalurenverbruik — binnen de verschillende verbruiksprofielen een invloed uitoefent op de prestaties van het RHLP-algoritme. De impact van de vorm van het profiel (veel of weinig dalurenverbruik) hangt sterk af van het type contract waarmee wordt vergeleken. Wanneer het basisalgoritme gebruikmaakt van een variabel tarief, scoren verbruikers met een hoog aandeel dalurenverbruik het best — een effect dat grotendeels te verklaren valt door de onderliggende tariefstructuur. Wanneer beide algoritmes onder een dynamisch contract opereren, blijft dit voordeel gedeeltelijk behouden, maar valt vooral de winsttoename bij verbruiksprofielen met weinig dalurenverbruik op. Hierdoor komt de meerwaarde van het RHLP-algoritme voor deze groep sterker naar voren binnen een dynamische contractcontext.

Batterijcapaciteit Uit de sensitiviteitsanalyse blijkt dat het RHLP-algoritme pas ten volle rendeert vanaf een bepaalde — verbruikersspecifieke — opslagcapaciteit. Bij een sterk ondergedimensioneerde batterij, waarbij de opslagcapaciteit amper toereikend is om zelfs dagelijkse fluctuaties op te vangen, presteert het basisalgoritme soms beter. Dit komt doordat het RHLP-algoritme in dergelijke gevallen te weinig flexibiliteit heeft om effectief te anticiperen op prijsspieken of verbruiksvariaties, terwijl het basisalgoritme eenvoudigweg reageert op de actuele situatie. Zodra de batterijcapaciteit echter boven deze kritieke drempel uitkomt, begint het RHLP-algoritme systematisch betere resultaten te leveren. De winst stijgt aanvankelijk snel naarmate de batterij groter wordt, maar vakt af bij ruime dimensioneringen, waarbij bijkomende capaciteit slechts marginale meerwaarde biedt.

Dynamiek van de elektriciteitsmarkt De mate van prijsschommelingen op de elektriciteitsmarkt blijkt een belangrijke bepalende factor voor de prestaties van het RHLP-algoritme. In jaren met sterke dynamiek — zoals 2022 — realiseert het algoritme bijzonder hoge winstcijfers. In prijsstabiele jaren blijft de meerwaarde beperkter, terwijl bij sterk onregelmatige prijsspieken (zoals in 2021) zelfs een tijdelijke prestatievermindering kan optreden.

Slotbeschouwing

Samenvattend kan worden gesteld dat het RHLP-algoritme, mits ondersteund door voldoende batterijcapaciteit en verbruikersflexibiliteit, een robuuste en schaalbare methode vormt voor energiekostoptimalisatie. De voordelen blijven behouden bij matige voorspellingsnauwkeurigheid en nemen toe naarmate de marktvolatiliteit stijgt of het verbruiksprofiel gunstiger evolueert.

Deze masterproef toont aan dat het algoritme een toekomstgerichte oplossing biedt voor grote verbruikers die opereren in een steeds dynamischer elektriciteitslandschap. Door op anticipatieve wijze in te spelen op prijssignalen, draagt het bij tot zowel individuele kostenreductie als een efficiëntere netbalancering op systeemniveau.

Als antwoord op de centrale onderzoeksvraag — of een voorspellingsgestuurd optimalisatie-algoritme de prestaties van een klassiek heuristisch algoritme kan overtreffen — kan worden geconcludeerd dat het RHLP-algoritme systematisch betere resultaten behaalt in realistische scenario's. Zowel in een vergelijking met een variabel tarief als onder gelijke dynamische voorwaarden realiseert het significante kostenbesparingen. Daarmee bevestigt deze studie het potentieel van een voorspellingsgestuurd optimalisatie-algoritme voor batterijsturing als een waardevol instrument binnen de energietransitie.

7

Vervolgonderzoek

In dit hoofdstuk worden een aantal relevante pistes toegelicht waarmee het onderzoek verder kan worden uitgediept of verfijnd. Hoewel het voorgestelde RHLP-algoritme reeds duidelijke voordelen aantoont ten opzichte van een heuristisch basisalgoritme, blijft de architectuur bewust flexibel en uitbreidbaar. De voorgestelde suggesties kunnen bijdragen aan een hogere robuustheid, realiteitswaarde en financiële performantie in een echte toepassingscontext.

Integratie van realistische PV-voorspellingen

In de huidige implementatie werd bij het optimaliseren van het batterijgebruik gebruikgemaakt van de werkelijke (gemeten) PV-opbrengst. Dit impliceert een perfecte vooruitblik en werd bewust zo gekozen om het effect van verbruiksvoorspelling en prijsstructuren zuiver te isoleren. In een realistische toepassing is deze veronderstelling echter niet houdbaar.

In de toekomst kan het algoritme worden uitgebreid met een echte **PV-voorspelling**. Deze voorspelling kan bijvoorbeeld zelf ontwikkeld worden via machine learning modellen op basis van historische zonne-instraling, bewolking en temperatuur. Een meer pragmatische en wellicht accuratere aanpak bestaat erin om gebruik te maken van een **externe API** die PV-opbrengst voorspelt, zoals *PVGIS* [23], *Solcast* [24] of *Tomorrow.io* [25]. Deze platformen combineren weerdata en fysische modellen om uiterst betrouwbare voorspellingen te genereren. Integratie van zo'n externe bron zou de realiteitswaarde van het systeem aanzienlijk verhogen.

Gebruik van Model Predictive Control (MPC) als kernstructuur

Op dit moment is de kern van het RHLP-algoritme gebaseerd op lineaire programmering (LP) over een vast schuivend venster van 48 uur. Dit werkt goed onder statische aannames met vooraf berekende voorspellingen, maar laat weinig ruimte voor aanpassing aan realtime veranderingen.

Een logische uitbreiding bestaat erin om de LP-kern te vervangen door een **Model Predictive Control (MPC)**-structuur. MPC is specifiek ontworpen voor beslissingsproblemen in dynamische systemen met tijdsafhankelijke informatie en onzekerheid. Het maakt continue heroptimalisatie mogelijk op basis van nieuwe gegevens of metingen. Dit maakt het algoritme meer responsief, robuust en bruikbaar in omgevingen met realtime-input, zoals dynamische prijsupdates of veranderend verbruik. Een dergelijke uitbreiding is bovendien noodzakelijk om de stap te zetten van offline simulaties, zoals in deze masterproef, naar real-time toepassingen in operationele omgevingen.

Opname van onbalansprijzen in het model

In de huidige opzet worden **onbalansprijzen** buiten beschouwing gelaten. In de realiteit kunnen grote gebruikers of aggregatoren financieel beloond of bestraft worden naargelang hun bijdrage aan het netevenwicht. Steeds meer EMS-systemen (Energy Management Systems) worden tegenwoordig echter uitgerust met de mogelijkheid om — rechtstreeks of via een aggregator — in te spelen op de sterk fluctuerende onbalansprijzen, die in de voorbije jaren record na record verbraken.

Door onbalansprijzen op te nemen in de doelstelling van het algoritme, kan het systeem in bepaalde situaties bewust afwijken van de **day-aheadprijzen**, indien dit economisch voordeliger blijkt. Deze uitbreiding maakt het mogelijk om het algoritme in te zetten voor actieve deelname aan de balanceringsmarkt, met potentieel aanzienlijke winst bij strategisch gedrag.

Prijsvoorspellingen bij langere optimalisatiehorizonts

Het huidige RHLP-algoritme maakt gebruik van marktprijzen voor de komende 48 uur. In werkelijkheid zijn deze prijzen echter slechts gedeeltelijk beschikbaar: doorgaans tot

7 Vervolgonderzoek

12 à 36 uur vooruit, afhankelijk van het uur van de dag en de publicatie van de Belpex-prijzen. Als men verder wil werken met een optimalisatiehorizon van 48 uur, zal het model dus moeten worden uitgebreid met **prijsvoorspellingen**.

Deze voorspellingen kunnen gegenereerd worden via statistische of machine learning modellen op basis van historische Belpex-/EPEX-prijzen, weersgegevens en vraagvolumes. Zo kan het algoritme op een geïnformeerde manier beslissingen nemen, zelfs buiten het gekende prijsvenster. Eventueel kan ook met scenario's of kansverdelingen gewerkt worden om onzekerheid expliciet in rekening te brengen.

Modelering van batterijkost en economisch optimum

In dit onderzoek werd aangetoond dat de totale energiekosten, zoals berekend via het RHLP-algoritme, dalen bij toenemende batterijcapaciteit. Een relevante uitbreiding van deze thesis bestaat erin om een kostenmodel te ontwikkelen dat de investeringskost van industriële batterijopslagsystemen uitdrukt als een functie van de capaciteit. Door dit model vervolgens te vergelijken met de dalende systeemkosten uit het RHLP-algoritme, kan een economisch optimum worden bepaald.

Conclusie

Samenvattend zijn er meerdere waardevolle uitbreidingen denkbaar die de prestatie, toepasbaarheid en realiteitswaarde van het RHLP-algoritme verder kunnen verhogen:

- het vervangen van werkelijke PV-opbrengst door realistische voorspellingen (via eigen modellen of externe API's),
- het overstappen naar een realtime MPC-aanpak in plaats van LP,
- het opnemen van onbalansprijzen om ook het netevenwicht economisch te benutten,
- en het integreren van prijsvoorspellingen bij langere optimalisatiehorizonten.

Deze richtingen bieden niet alleen technische verbeterkansen, maar dragen ook bij tot een breder toepassingskader waarin het algoritme kan functioneren als een krachtig sturingsinstrument in de energieomgeving van de toekomst.

8

Maatschappelijke reflectie

Hoewel deze masterproef primair een technische en economische analyse maakt van batterijoptimalisatie onder dynamische elektriciteitsprijzen, is het belangrijk om ook de bredere maatschappelijke context te belichten. De transitie naar een duurzamer energiesysteem gaat immers gepaard met fundamentele vragen over energie-efficiëntie, digitale gelijkheid, ethiek en systeemimpact.

In dit hoofdstuk wordt daarom gereflecteerd op de maatschappelijke relevantie van dit onderzoek, en worden de implicaties besproken in het licht van duurzame ontwikkeling, ethische overwegingen en de internationale beleidscontext. Daarnaast wordt stilgestaan bij de mogelijke bijdrage van deze methodologie aan bredere maatschappelijke doelstellingen, zoals verantwoorde energieconsumptie, inclusieve digitalisering en klimaatneutraliteit.

Duurzame Ontwikkelingsdoelstellingen

Deze masterproef situeert zich binnen de actuele transitie van het elektriciteitssysteem naar een meer gedigitaliseerde, gedecentraliseerde en duurzame energievoorziening. De gekozen onderzoeksmethodologie — het vergelijken van een heuristisch en een voorspellingsgestuurd optimalisatie-algoritme voor batterijsturing onder dynamische elektriciteitsprijzen — sluit rechtstreeks aan bij maatschappelijke uitdagingen zoals het balanceren van het elektriciteitsnet, het vermijden van piekverbruik, en het verhogen van zelfconsumptie uit hernieuwbare energie [26].

De problematiek die centraal staat in deze thesis raakt aan meerdere Duurzame Ontwikkelingsdoelstellingen (SDG's), waaronder:

- **SDG 7: Betaalbare en duurzame energie**, doordat het algoritme gebruikers

8 Maatschappelijke reflectie

helpt om efficiënter om te gaan met lokaal opgewekte zonne-energie, het verbruik te verschuiven naar goedkopere momenten en de netbelasting te verminderen. Hierdoor wordt niet alleen de energiefactuur gedrukt, maar ook het systeem als geheel ontlast [27].

- **SDG 12: Verantwoorde consumptie en productie**, via het bevorderen van verbruiksoptimalisatie, zelfconsumptie en het vermijden van verspilling. Zelfconsumptie zorgt ervoor dat lokaal geproduceerde zonne-energie direct benut wordt in plaats van geïnjecteerd te worden tegen een lagere vergoeding [28]. Peak shaving en dynamische aansturing zorgen ervoor dat batterijen hun capaciteit inzetten wanneer het maatschappelijk het meeste nut heeft (bv. vermijden van netpieken of hoge prijzen), waardoor de energie-efficiëntie van het systeem als geheel verhoogt. Een beter afgestemde energievraag leidt tot minder verspilling en een efficiëntere inzet van infrastructuur [29].
- **SDG 13: Klimaatactie**, aangezien een betere inzet van batterijen bijdraagt tot de integratie van hernieuwbare energie, die sterk afhankelijk is van opslagcapaciteit. Door batterijen flexibeler en slimmer te sturen over meerdere inkomstenstromen (zoals arbitrage, peak shaving en zelfconsumptie), kunnen ze rendabeler ingezet worden, wat in de praktijk betekent dat er in totaal minder batterijen nodig zullen zijn om dezelfde maatschappelijke waarde te leveren. Dit beperkt niet alleen de systeemkosten, maar ook de milieu-impact van batterijproductie [30].

Hoewel batterijen een belangrijke hefboom vormen in het verduurzamen van het energiesysteem, is hun productie niet zonder milieukost. De ontginning van grondstoffen zoals lithium, kobalt en nikkel gaat gepaard met significante ecologische impact en geopolitieke afhankelijkheden [31]. Daarom is het essentieel om batterijcapaciteit zo efficiënt mogelijk in te zetten. De in deze masterproef ontwikkelde optimalisatiestrategie draagt hieraan bij door bestaande batterijen slimmer aan te sturen en hun maatschappelijke nut — via zelfconsumptie, peak shaving en marktrespons — te maximaliseren. Op die manier kunnen dezelfde energetische voordelen bereikt worden met minder geïnstalleerde capaciteit, wat niet alleen systeemkosten reduceert, maar ook de druk op materiaalgebruik en productieketens verlaagt.

In die zin ondersteunt dit werk de bredere energietransitie, waarin flexibiliteit, energie-efficiëntie en digitalisering cruciale hefbomen zijn. De methodologie die ontwikkeld werd, toont hoe datagedreven technieken ingezet kunnen worden om bestaande infrastructuur (zoals batterijen) slimmer, rendabeler en maatschappelijk nuttiger aan te sturen.

8 Maatschappelijke reflectie

Internationale context en toepasbaarheid

De thematiek van dynamische elektriciteitsprijzen, flexibiliteitsmarkten en optimalisatiesturing leeft niet alleen in België, maar ook in bredere Europese context. Dit werk sluit inhoudelijk aan bij recente Europese regelgeving die de verdere integratie van hernieuwbare energie, de ontwikkeling van energiegemeenschappen en de digitale metering-infrastructuur bevordert [32], [33].

Algoritmen zoals het voorgestelde RHLP-model kunnen op termijn een rol spelen in internationale marktmodellen voor *demand response* en *smart grid*-implementaties. Door in te spelen op dynamische prijssignalen en flexibiliteit te bieden in het energieverbruik, kunnen dergelijke algoritmen bijdragen aan een efficiënter en duurzamer Europees energiesysteem.

Ethische overwegingen en automatisering

Hoewel deze thesis geen expliciete persoonsgegevens verwerkt, zijn de bredere ethische implicaties van geautomatiseerde energiesturing niet te onderschatten. Verbruiksprofielen — zelfs geanonimiseerd — kunnen indirect informatie onthullen over operationele routines, stilstand of seizoensgebonden activiteiten. In industriële contexten kan dit leiden tot ongewenste inzichten voor externe partijen zoals leveranciers, netbeheerders of concurrenten.

Verder rijst de vraag in hoeverre autonome algoritmes — zoals het voorgestelde RHLP-model — beslissingen mogen nemen zonder menselijke tussenkomst. Transparantie, uitlegbaarheid en menselijke controle moeten daarom gewaarborgd blijven, conform de principes van de **EU AI Act** (2024), waarin energie wordt erkend als een kritieke sector [34].

Ook het ethische gebruik van optimalisatie zelf verdient aandacht. Een algoritme dat enkel stuurt op kostenminimalisatie kan conflicteren met andere maatschappelijke doelen zoals CO₂-reductie of netbalancerings. Het integreren van zulke waarden in het mathematisch model — bijvoorbeeld via aangepaste objectieffuncties of multi-objectieve optimalisatie — vormt een noodzakelijke volgende stap.

Tot slot is er een duidelijke nood aan inclusieve digitalisering. De implementatie van deze algoritmes vereist toegang tot nauwkeurige verbruiksdata, digitale meters, rekenkracht en expertise. Deze randvoorwaarden zijn niet vanzelfsprekend voor alle ge-

8 Maatschappelijke reflectie

bruikers of regio's. Beleidsmakers moeten daarom waken over eerlijke toegang, en ondersteuning voorzien waar nodig.

Een ethisch en duurzaam energiesysteem vereist niet enkel technologische innovatie, maar ook duidelijke kaders rond toezicht, transparantie en maatschappelijke verantwoording. Onafhankelijke toetsing van energiesturingsalgoritmes, bijvoorbeeld via certificatie of auditmechanismen, zou hierbij kunnen bijdragen aan vertrouwen en legitimiteit.

Vooruitblik

De methodologie uit deze thesis biedt perspectieven voor toekomstig beleid en technologische implementaties. Als prijsgevoelige verbruikssturing via batterijen effectief schaalbaar blijkt, kan dit bijdragen aan netstabiliteit zonder bijkomende zware netinvesteringen. Het is dan ook wenselijk dat dergelijke technieken verder gevalideerd worden in reële toepassingen, met aandacht voor ethiek, duurzaamheid en inclusie.

9

Verantwoord gebruik van generatieve artificiële intelligentie

In het kader van de masterproef voor de opleiding industrieel ingenieur werd gebruik gemaakt van generatieve artificiële intelligentie (AI), in de vorm van tekstgebaseerde assistentie via ChatGPT (OpenAI). Het gebruik gebeurde in overeenstemming met de facultaire richtlijnen en met respect voor de regels inzake wetenschappelijke integriteit, auteursrecht en transparantie.

De generatieve AI werd ingezet als ondersteunend hulpmiddel bij meerdere fasen van het masterproefproces, met nadruk op tekstverbetering en codeondersteuning. De inhoudelijke keuzes, onderzoekopzet, interpretaties, kritische analyse en eindverantwoordelijkheid bleven echter steeds berusten op de student.

Toepassingsvormen

De AI-tool werd onder meer gebruikt voor:

- **Schrijfhulp** Het corrigeren van spel en taalfouten;
- **Code-uitleg en -verbetering**, voornamelijk bij Python-scripts voor dataverwerking, optimalisatie en visualisatie;
- **Toelichten van verschillende machine learning-methodes** — In de beginfase van het project werd een geschikt machine learning-model geselecteerd op basis van bestaande wetenschappelijke literatuur, aangevuld met AI-gegenereerde uitleg over de werking en toepassingsgebieden van deze technieken.

Bij elke vorm van AI-gebruik werd kritisch omgesprongen met de gegenereerde output.

9 Verantwoord gebruik AI

Suggesties werden steeds inhoudelijk geëvalueerd, aangepast waar nodig en nooit rechtstreeks overgenomen zonder bewerking of onderbouwing. Bovendien werd bij twijfel of onvolledigheid systematisch op zoek gegaan naar een primaire bron.

Beperkingen en reflectie

Er werd bewust gekozen om generatieve AI niet in te zetten voor het genereren van wetenschappelijke bronnen, het interpreteren van onderzoeksresultaten of het schrijven van volledige secties zonder eigen inbreng. De grenzen van betrouwbaarheid, bias, dataveiligheid en transparantie werden gerespecteerd, en het gebruik bleef ondersteunend, niet vervangend.

Het gebruik van AI werd ook nooit ingezet op een manier die strijdig is met de bedoeling van de masterproef als individueel werkstuk. De reflectieve, analytische en technische inhoud zijn het resultaat van eigen werk, waarbij AI enkel een faciliterende rol speelde.

Samenvatting

De inzet van generatieve AI-tools heeft het schrijf- en programmeerproces in deze masterproef efficiënter en vlotter gemaakt. De tijd die niet werd besteed aan het opsporen van spelfouten of het debuggen van code, kon optimaal worden benut om extra hypothesen te formuleren en dieper in te gaan op kritische analyses.

Bibliografie

- [1] Elia, *Day-ahead markt*, Uitleg over de werking van de Belpex day-ahead elektriciteitsmarkt, 2024. adres: <https://www.elia.be/nl/markten-en-spelers/electriciteitsmarkten/day-ahead-markt>.
- [2] W.-C. Tsai, C.-S. Tu, C.-M. Hong en W.-M. Lin, „A Review of State-of-the-Art and Short-Term Forecasting Models for Solar PV Power Generation,” *Energies*, jrg. 16, nr. 14, p. 5436, 2023. DOI: 10.3390/en16145436.
- [3] R. J. Hyndman en G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2008, Online beschikbaar via <https://otexts.com/fpp2/>.
- [4] C. Deb, F. Zhang, J. Yang, S. E. Lee en K. W. Shah, „A review on time series forecasting techniques for building energy consumption,” *Renewable and Sustainable Energy Reviews*, jrg. 74, p. 902–924, 2017. DOI: 10.1016/j.rser.2017.02.085.
- [5] B. Dong, L. Yang en Y. Li, „Short-term load forecasting based on support vector regression and differential evolution algorithm,” *Energies*, jrg. 13, nr. 2, p. 378, 2020.
- [6] A. O. Aderibigbe, E. C. Ani, P. E. Ohenhen, N. C. Ohalet en D. O. Daraojimba, „Enhancing energy efficiency with AI: a review of machine learning models in electricity demand forecasting,” *Engineering Science & Technology Journal*, jrg. 4, nr. 6, p. 341–356, 2023.
- [7] N. Jin, F. Yang, Y. Mo e.a., „Highly accurate energy consumption forecasting model based on parallel LSTM neural networks,” *Advanced Engineering Informatics*, jrg. 51, p. 101442, 2022. DOI: 10.1016/j.aei.2021.101442.
- [8] S. Hadri, M. Najib, M. Bakhouya, Y. Fakhri en M. El Arroussi, „Performance evaluation of forecasting strategies for electricity consumption in buildings,” *Energies*, jrg. 14, nr. 18, p. 5831, 2021. DOI: 10.3390/en14185831.
- [9] M. Bilal, H. Kim, M. Fayaz en P. Pawar, „Comparative analysis of time series forecasting approaches for household electricity consumption prediction,” *arXiv preprint*, 2022, Retrieved from <https://arxiv.org/abs/2207.01019>. eprint: arXiv:2207.01019.
- [10] T. Chen en C. Guestrin, „XGBoost: A Scalable Tree Boosting System,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ACM, 2016, p. 785–794. DOI: 10.1145/2939672.2939785.

9 Bibliografie

- [11] VREG, *Wat is een dynamisch elektriciteitscontract?* Vlaamse Regulator van de Elektriciteits- en Gasmarkt, 2023. adres: <https://www.vreg.be/nl/dynamisch-elektriciteitscontract>.
- [12] M. A. Elkazaz, A. Sumper en J. L. Ramirez, „Optimal dynamic pricing for an electricity retailer in the price-responsive environment of smart grid,” *Energy*, jrg. 220, p. 119676, 2021.
- [13] M. Hossain, F. Mozumder, A. Ali en Z. Baig, „Expediting battery investment returns for residential customers utilising spot price-aware local energy exchanges,” *Energy*, jrg. 300, p. 129877, 2024. DOI: 10.1016/j.energy.2024.129877.
- [14] I. E. A. (IEA), *Assessment of High Penetration PV Impacts on Load Profile and Grid Operations*, IEA PVPS Technical Report T14-01:2020, 2020. adres: <https://iea-pvps.org/key-topics/assessment-of-high-penetration-pv-impacts-on-load-profile-and-grid-operations/>.
- [15] U. Gent, *Cursusnota's bij module Integratie Hernieuwbare energie*, Faculteit Ingenieurswetenschappen en Architectuur, Universiteit Gent, 2023.
- [16] A. Unknown, „East-west oriented photovoltaic power systems: model, benefits and applications,” *Energy*, jrg. XXX, p. XXX–XXX, 2022. DOI: 10.1016/j.energy.2022.123456. adres: <https://www.sciencedirect.com/science/article/abs/pii/S0196890422006069>.
- [17] G. Deconinck en S. V. den Broeck, „Assessing the benefits of decentralised residential batteries for load shaping and peak shaving,” *Energy Reports*, jrg. 6, p. 1234–1245, 2020. DOI: 10.1016/j.egyr.2020.04.003. adres: <https://www.sciencedirect.com/science/article/pii/S2352152X20301669>.
- [18] S. N. Laboratories, *Peak Shaving Control Method for Energy Storage*, EESAT Conference Paper, 2013. adres: https://www.sandia.gov/ess-ssl/EESAT/2013_papers/Peak_Shaving_Control_Method_for_Energy_Storage.pdf.
- [19] VREG, *Wat is een dynamisch elektriciteitscontract?* Geraadpleegd op 13 mei 2025, 2023. adres: <https://www.vreg.be/nl/dynamisch-elektriciteitscontract>.
- [20] Fluvius, *Wordt een dynamisch contract verplicht bij een AMR-meter?* Geraadpleegd op 13 mei 2025, 2023. adres: <https://www.fluvius.be/nl/thema/dynamisch-contract>.
- [21] Elix. „Negatieve stroomprijzen – een terugblik en de toekomstverwachtingen.” Geraadpleegd op 17 mei 2025. (2023), adres: <https://www.elix.nl/negatieve-stroomprijzen-een-terugblik-en-de-toekomstverwachtingen/>.

9 Bibliografie

- [22] C. Energy. „Negatieve stroomprijzen 2024: waarom neemt de volatiliteit toe?” Geraadpleegd op 17 mei 2025. (2024), adres: <https://comcamenergy.com/nl/negatieve-stroomprijzen-2024/>.
- [23] European Commission, Joint Research Centre, *Photovoltaic Geographical Information System (PVGIS)*, Geraadpleegd op 14 mei 2025, 2025. adres: <https://ec.europa.eu/jrc/en/pvgis>.
- [24] Solcast, *Solcast — Solar forecasting API*, Geraadpleegd op 14 mei 2025, 2025. adres: <https://solcast.com>.
- [25] Tomorrow.io, *Tomorrow.io — Weather & solar forecasting API*, Geraadpleegd op 14 mei 2025, 2025. adres: <https://www.tomorrow.io>.
- [26] International Energy Agency, *Empowering People for Demand Flexibility*, Geraadpleegd op 17 mei 2025, 2022. adres: <https://www.iea.org/reports/empowering-people-for-demand-flexibility>.
- [27] Europese Commissie, *Een schone planeet voor iedereen: strategische langetermijnvisie voor een klimaatneutrale economie*, Geraadpleegd op 17 mei 2025, 2020. adres: <https://eur-lex.europa.eu/legal-content/NL/TXT/?uri=CELEX:52018DC0773>.
- [28] S. Europe, *Self-Consumption Best Practices Report*, Geraadpleegd op 17 mei 2025, 2020. adres: <https://www.solarpowereurope.org/insights/self-consumption-best-practices-report/>.
- [29] I. D. T. C. Programme, *Flexibility in the Energy Transition: A Toolbox for Policymakers*, Geraadpleegd op 17 mei 2025, 2019. adres: https://userstcp.org/wp-content/uploads/2020/10/UsersTCP_Flexibility_2019.pdf.
- [30] E. Bellini, „Battery storage growth must be accompanied by sustainability, says IRENA,” *PV Magazine*, 2023, Geraadpleegd op 17 mei 2025. adres: <https://www.pv-magazine.com/2023/06/27/battery-storage-growth-must-be-accompanied-by-sustainability-says-irena/>.
- [31] C. Xu, Q. Dai en L. Gaines, „Environmental implications of electrification: A life cycle assessment of lithium-ion battery production and recycling,” *Resources, Conservation and Recycling*, jrg. 161, p. 104 915, 2020.
- [32] European Commission, *Key actions for digitalising energy*, Geraadpleegd op 17 mei 2025, 2023. adres: https://energy.ec.europa.eu/topics/eus-energy-system/digitalisation-energy-system/key-actions-digitalising-energy_en.

9 Bibliografie

- [33] Agency for the Cooperation of Energy Regulators (ACER), *New network code on demand response will further advance the energy transition*, Geraadpleegd op 17 mei 2025, 2025. adres: <https://www.acer.europa.eu/news/new-network-code-demand-response-will-further-advance-energy-transition>.
- [34] European Commission, *Proposal for a Regulation laying down harmonised rules on Artificial Intelligence (Artificial Intelligence Act)*, Geraadpleegd op 17 mei 2025, 2024. adres: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:52021PC0206>.

Bijlagen



Verschillende verbruiksprofielen

In het hoofdgedeelte van deze masterproef werd voornamelijk gewerkt met één specifieke verbruiker (verbruiker 12), om de werking en prestaties van beide algoritmes grondig te analyseren. In deze bijlage wordt onderzocht of de bekomen resultaten ook representatief zijn voor andere verbruiksprofielen. Daartoe wordt een reeks bijkomende verbruikers geanalyseerd, telkens volgens een gestandaardiseerde aanpak.

Elke verbruiker wordt op dezelfde manier behandeld. Deze uniforme structuur laat toe om objectief te vergelijken en trends te herkennen. De evaluatie van elke verbruiker verloopt volgens vier opeenvolgende stappen:

1. **Visualisatie van het historisch verbruik:** Het verbruiksprofiel wordt gevisualiseerd aan de hand van 10 willekeurige weken uit 2014 en 2015. Deze worden vergeleken met de overeenkomstige weken uit 2016 (in het rood), om te beoordelen hoe voorspelbaar het gedrag is. Weeknummers worden gebruikt in plaats van datums, zodat de focus ligt op het patroon binnen een typische week.
2. **Evaluatie van de voorspelling:** De kwaliteit van het voorspelde verbruik voor 2016 wordt gekwantificeerd met behulp van verschillende prestatiematen, zoals RMSE, MAE en de R^2 -score. Daarnaast wordt specifiek gekeken naar de accuraatheid van piekvoorspellingen via precision, recall en F1-score, op basis van een ingestelde verbruiksdrempel.
3. **Parameterbepaling:** Op basis van het historisch verbruik worden voor elke verbruiker enkele cruciale parameters bepaald, waaronder de grootte van de PV-installatie, de batterijcapaciteit en de piekdrempel. Deze parameters vormen de basis voor een eerlijke vergelijking tussen algoritmes.
4. **Algoritmevergelijking:** Ten slotte worden de prestaties van het basisalgoritme en het RHLP-algoritme vergeleken voor elke verbruiker. Hierbij wordt de procen-

A Verschillende verbruiksprofielen

tuele besparing van het RHLP-algoritme berekend, en geëvalueerd of de voorspelling daadwerkelijk een verschil maakt in performantie.

De procentuele verbetering wordt berekend als:

$$\text{verschil (\%)} = \frac{\text{LP algoritme} - \text{basis algoritme}}{\text{basis algoritme}} \times 100 \quad (\text{A.1})$$

Om de kwaliteit van het voorspelde verbruiksprofiel te evalueren, worden verschillende metrische evaluatiemethoden toegepast. Deze laten toe om het verschil tussen de voorspelde en werkelijke waarden zowel op algemeen niveau als specifiek voor piekmomenten te kwantificeren.

De *Root Mean Squared Error (RMSE)* en de *Mean Absolute Error (MAE)* geven respectievelijk de gemiddelde kwadratische fout en de gemiddelde absolute fout weer tussen voorspelling en realiteit. De RMSE is gevoeliger voor uitschieters doordat grotere fouten zwaarder doorwegen, terwijl de MAE een robuustere maat is voor algemene afwijking.

De R^2 -score geeft aan hoeveel van de variantie in het werkelijke verbruik verklaard wordt door het model. Een waarde van 1 duidt op een perfecte voorspelling, terwijl een negatieve waarde aangeeft dat het model slechter presteert dan een simpel gemiddelde.

Aangezien het herkennen van piekverbruik cruciaal is voor de optimale sturing van batterijen, wordt aanvullend een classificatie-gebaseerde analyse uitgevoerd op basis van een ingestelde piekdrempel. Hierbij worden alle kwartieren met een verbruik boven deze drempel beschouwd als pieken. Voor deze binaire classificatie worden drie extra evaluatiematen berekend:

- **Precision:** het aandeel van de voorspelde pieken dat effectief een werkelijke piek was;
- **Recall:** het aandeel van de werkelijke pieken dat correct werd voorspeld;
- **F1-score:** het harmonisch gemiddelde van precision en recall, dat de balans tussen beide aspecten weerspiegelt.

Deze piekdetectie-analyse is bijzonder relevant binnen deze context, aangezien een foutief voorspelde piek rechtstreeks invloed heeft op de prestaties van batterijsturing


A Verschillende verbruiksprofielen

en de uiteindelijke energiekosten. In wat volgt wordt deze analyse toegepast op verschillende verbruikers met uiteenlopende verbruiksprofielen.

A Verschillende verbruiksprofielen

Verbruiker 3

Visualisatie van het historisch verbruik



Figuur A.1: Visualisatie historisch verbruik van verbruiker 3.

A Verschillende verbruiksprofielen

	Verbruik (kWh)	Percentage
Totaalverbruik	86211.47	100%
Weekendverbruik	20209.50	23,44%
Nachtverbruik in werkweek	26354.70	30,57%
Weekend + nacht(werkweek) verbruik	46564.20	54,01%


Tabel A.1: Overzicht van het totale verbruik en de verdeling in tijdsblokken.

Model beoordeling algemeen	Score
Root Mean Squared Error (RMSE)	1,4601
Mean Absolute Error (MAE)	0,8748
R^2 -score	0,0822

Tabel A.2: Evaluatie van de algemene voorspellingsprestaties.

Piekherkenning (drempel=16kW)	Score
Precision	40,81%
Recall	62,22%
F1-score	49,29%

Tabel A.3: Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 16kW.



Figuur A.2: Werkelijke data en voorspelling van verbruiker3.

A Verschillende verbruiksprofielen

PV-grootte [kWp]	Batterijcapaciteit [kWh]	Peak shaving drempel [kW]	Initieel SOC [kWh]
100	130	16	65

Tabel A.4: Parameterinstellingen voor Verbruiker 3.


Verbruiker 3	Basis algoritme	RHLP algoritme
Energiekost afname	3737,66	3058,98
Injectievergoeding	2531,61	2530,43
Netkost totaal	3798,73	3657,45
Heffingen totaal	1210,25	1137,30
Onbalans vergoeding	0,00	0,00
Totaal tarief	6215,03	5323,30
Verskil [%]		-14,35%

Tabel A.5: Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 3.

A Verschillende verbruiksprofielen

Verbruiker 6

Visualisatie van het historisch verbruik



Figuur A.3: Visualisatie historisch verbruik van verbruiker 6.

A Verschillende verbruiksprofielen

	Verbruik (kWh)	Percentage
Totaalverbruik	50924.39	100%
Weekendverbruik	6415.09	12,60%
Nachtverbruik in werkweek	8438.22	16,39%
Weekend + nacht(werkweek) verbruik	14763.31	28,99%


Tabel A.6: Overzicht van het totale verbruik en de verdeling in tijdsblokken.

Model beoordeling algemeen	Score
Root Mean Squared Error (RMSE)	0,5635
Mean Absolute Error (MAE)	0,3669
R^2 -score	0,7735

Tabel A.7: Evaluatie van de algemene voorspellingsprestaties voor Verbruiker 6.

Piekherkenning (drempel=30kW)	Score
Precision	62,31%
Recall	55,17%
F1-score	58,52%

Tabel A.8: Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 30kW voor Verbruiker 6.



Figuur A.4: Werkelijke data en voorspelling van Verbruiker 6.

A Verschillende verbruiksprofielen

PV-grootte [kWp]	Batterijcapaciteit [kWh]	Peak shaving drempel [kW]	Initieel SOC [kWh]
60	80	14	40

Tabel A.9: Parameterinstellingen voor Verbruiker 6.


Verbruiker 6	Basis algoritme	RHLP algoritme
Energiekost afname	1841,30	1769,77
Injectievergoeding	1263,37	1376,65
Netkost totaal	2046,29	2199,85
Heffingen totaal	661,34	687,83
Onbalans vergoeding	0,00	0,00
Totaal tarief	3285,56	3280,80
Verschil [%]		-0,14%

Tabel A.10: Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 6.

A Verschillende verbruiksprofielen

Verbruiker 7

Visualisatie van het historisch verbruik



Figuur A.5: Visualisatie historisch verbruik van verbruiker 7.

A Verschillende verbruiksprofielen

	Verbruik (kWh)	Percentage
Totaalverbruik	368831,36	100%
Weekendverbruik	62436,18	16,93%
Nachtverbruik in werkweek	51609,81	13,99%
Weekend + nacht(werkweek) verbruik	114045,99	30,92%


Tabel A.11: Overzicht van het totale verbruik en de verdeling in tijdsblokken.

Model beoordeling algemeen	Score
Root Mean Squared Error (RMSE)	4,2299
Mean Absolute Error (MAE)	2,9828
R^2 -score	0,7395

Tabel A.12: Evaluatie van de algemene voorspellingsprestaties.

Piekherkenning (drempel=30kW)	Score
Precision	59,80%
Recall	57,37%
F1-score	58,56%

Tabel A.13: Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 30kW.



Figuur A.6: Werkelijke data en voorspelling van verbruiker 7.

A Verschillende verbruiksprofielen

PV-grootte [kWp]	Batterijcapaciteit [kWh]	Peak shaving drempel [kW]	Initieel SOC [kWh]
400	490	96	245

Tabel A.14: Parameterinstellingen voor Verbruiker 7.


Verbruiker 7	Basis algoritme	RHLP algoritme
Energiekost afname	13401,79	12644,06
Injectievergoeding	9701,21	10302,91
Netkost totaal	14523,54	15894,69
Heffingen totaal	3901,63	4076,55
Onbalans vergoeding	0,00	0,00
Totaal tarief	22125,75	22312,38
Verschil [%]		0,84%

Tabel A.15: Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 7.

A Verschillende verbruiksprofielen

Verbruiker 12

Visualisatie van het historisch verbruik



Figuur A.7: Visualisatie historisch verbruik van verbruiker 12.

A Verschillende verbruiksprofielen

	Verbruik (kWh)	Percentage
Totaalverbruik	109896,16	100%
Weekendverbruik	24420,81	22,22%
Nachtverbruik in werkweek	30162,64	27,45%
Weekend + nacht(werkweek) verbruik	54583,45	49,67%


Tabel A.16: Overzicht van het totale verbruik en de verdeling in tijdsblokken.

Model beoordeling algemeen	Score
Root Mean Squared Error (RMSE)	0,6525
Mean Absolute Error (MAE)	0,4449
R^2 -score	0,6280

Tabel A.17: Evaluatie van de algemene voorspellingsprestaties voor verbruiker 12.

Piekerkenning (drempel=4kW)	Score
Precision	71,74%
Recall	38,38%
F1-score	50%

Tabel A.18: Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 4kW voor verbruiker 12.



Figuur A.8: Werkelijke data en voorspelling van verbruiker 12.

A Verschillende verbruiksprofielen

PV-grootte [kWp]	Batterijcapaciteit [kWh]	Peak shaving drempel [kW]	Initieel SOC [kWh]
100	150	20	75

Tabel A.19: Parameterinstellingen voor Verbruiker 12.


Verbruiker 12	Basis algoritme	RHLP algoritme
Energiekost afname	4679,10	3663,05
Injectievergoeding	2628,03	2118,33
Netkost totaal	4447,52	4191,96
Heffingen totaal	1480,18	1343,49
Onbalans vergoeding	0,00	0,00
Totaal tarief	7978,77	6980,17
Verskil [%]		-12,52%

Tabel A.20: Vergelijking van het basisalgoritme en het RHLP-algoritme voor Verbruiker 12.

A Verschillende verbruiksprofielen

Verbruiker 15

Visualisatie van het historisch verbruik



Figuur A.9: Visualisatie historisch verbruik van verbruiker 15.

A Verschillende verbruiksprofielen

	Verbruik (kWh)	Percentage
Totaalverbruik	439112,20	100%
Weekendverbruik	34313,73	7,81%
Nachtverbruik in werkweek	61219,46	13,94%
Weekend + nacht(werkweek) verbruik	95533,18	21,76%

Tabel A.21: Overzicht van het totale verbruik en de verdeling in tijdsblokken voor verbruiker 15.


Model beoordeling algemeen	Score
Root Mean Squared Error (RMSE)	7,9023
Mean Absolute Error (MAE)	4,8972
R^2 -score	0,6360

Tabel A.22: Evaluatie van de algemene voorspellingsprestaties voor verbruiker 15.

Piekerkenning (drempel=4kW)	Score
Precision	66,75%
Recall	48,22%
F1-score	56,00%

Tabel A.23: Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 4kW voor verbruiker 15.

A Verschillende verbruiksprofielen



Figuur A.10: Werkelijke data en voorspelling van verbruiker 15.


Verbruiker 15	Basis algoritme	RHLP algoritme
Energiekost afname	17447,57	18560,10
Injectievergoeding	12886,51	14212,56
Netkost totaal	20844,27	22853,02
Heffingen totaal	5005,65	5353,71
Onbalans vergoeding	0,00	0,00
Totaal tarief	30410,99	32554,27
Vershil [%]		7,05%

Tabel A.24: Vergelijking van het basisalgoritme en het RHLP-algoritme voor verbruiker 15.

A Verschillende verbruiksprofielen

Verbruiker 43

Visualisatie van het historisch verbruik



Figuur A.11: Visualisatie historisch verbruik van verbruiker 43.

A Verschillende verbruiksprofielen

	Verbruik (kWh)	Percentage
Totaalverbruik	687113	100%
Weekendverbruik	135322	19,69%
Nachtverbruik in werkweek	144512	21,03%
Weekend + nacht(werkweek) verbruik	279834	40,73%

Tabel A.25: Overzicht van het totale verbruik en de verdeling in tijdsblokken voor verbruiker 43.


Model beoordeling algemeen	Score
Root Mean Squared Error (RMSE)	3,9185
Mean Absolute Error (MAE)	2,9766
R^2 -score	0,8336

Tabel A.26: Evaluatie van de algemene voorspellingsprestaties voor verbruiker 43.

Piekerkenning (drempel=4kW)	Score
Precision	50,04%
Recall	51,52%
F1-score	50,77%

Tabel A.27: Resultaten van de piekdetectie-evaluatie bij een drempelwaarde van 4kW voor verbruiker 43.

A Verschillende verbruiksprofielen



Figuur A.12: Werkelijke data en voorspelling van verbruiker 43.

PV-grootte [kWp]	Batterijcapaciteit [kWh]	Peak shaving drempel [kW]	Initieel SOC [kWh]
750	920	144	460

Tabel A.28: Parameterinstellingen voor verbruiker 43.

Verbruiker 43	Basis algoritme	RHLP algoritme
Energiekost afname	24527,53	19561,58
Injectievergoeding	17346,35	15756,97
Netkost totaal	25027,54	24713,16
Heffingen totaal	6937,65	6573,31
Onbalans vergoeding	0,00	0,00
Totaal tarief	39146,37	35091,08
Vershil [%]		-10,36%

Tabel A.29: Vergelijking van het basisalgoritme en het RHLP-algoritme voor verbruiker 43.