Q-GRID Abschlussbericht (E.ON)

Einleitung

Die zunehmende Komplexität zukünftiger Energienetze stellt Betreiber und Planer vor fundamentale Herausforderungen: Dezentralisierung durch erneuerbare Energien, volatile Einspeise- und Verbrauchsprofile, dynamische Netzbelastungen sowie steigende Anforderungen an Effizienz, Resilienz und Nachhaltigkeit verlangen nach neuen Optimierungsansätzen. Klassische Methoden zur Steuerung, Planung und Analyse stoßen hierbei zunehmend an ihre Grenzen – insbesondere bei kombinatorisch anspruchsvollen Aufgaben wie der Partitionierung von Stromnetzen in Microgrids, der gerechten Allokation von Netzkosten in Peer-to-Peer-Märkten oder der dynamischen Preisgestaltung zur Verbrauchslenkung. Diese Problemstellungen zeichnen sich oft durch eine hohe Zahl binärer Entscheidungsvariablen, komplexe Nebenbedingungen und nichtlineare Zielfunktionen aus, was sie in ihrer Struktur für klassische Algorithmen schwer lösbar macht. Vor diesem Hintergrund untersucht das Forschungsprojekt Q-Grid das Potenzial von Quantencomputing zur Bewältigung solcher hochdimensionalen Optimierungsprobleme. Insbesondere sogenannte QUBO-Modelle (Quadratic Unconstrained Binary Optimization) bilden hierbei eine zentrale Rolle, da sie sowohl von Quantenannealern als auch von hybriden und gate-basierten Quantenalgorithmen direkt verarbeitet werden können. Die Motivation liegt darin, durch geeignete Modellierungen, Vorverarbeitung und algorithmische Innovationen die besonderen Fähigkeiten von Quantencomputern – etwa bei der gleichzeitigen Auswertung vieler möglicher Lösungen durch Quantenparallelismus – für reale energiewirtschaftliche Anwendungsfälle nutzbar zu machen.
Im Projekt wurden deshalb gezielt drei exemplarische Use-Cases definiert, die verschiedene Aspekte zukünftiger Energienetze abbilden und gleichzeitig unterschiedliche algorithmische Anforderungen stellen:

1. Demand Side Response durch individuelle, CO_2-optimierte Preisgestaltung zur aktiven Verbrauchssteuerung
2. die Identifikation autarker Energiegemeinschaften durch graphbasierte Partitionierung unter Stromfluss- und Versorgungsrestriktionen sowie
3. die Kostenallokation in Peer-to-Peer-Märkten basierend auf physikalischen und logischen Leistungsflüssen.

Allen Use-Cases gemeinsam ist, dass sie komplexe, NP-schwere Optimierungsprobleme beinhalten, die sich zwar mit klassischen Methoden approximativ lösen lassen, deren Lösungsqualität und Skalierbarkeit jedoch stark begrenzt ist. Das Projekt Q-Grid setzt daher sowohl auf die Entwicklung neuartiger, quanteninspirierter Algorithmen, die problemstrukturierte Vorverarbeitung (z. B. durch Symmetriereduktion oder Zerlegungsmethoden) als auch auf die Integration und Evaluation von Quantentechnologien in realitätsnahen Szenarien. Ziel ist es, eine belastbare Einschätzung über das Potenzial und die praktischen Voraussetzungen quantenbasierter Optimierungsmethoden im Energiesektor zu erlangen – von der formalen Modellierung über die algorithmische Umsetzung bis hin zur realen oder simulierten Ausführung auf (hybrider) Quantenhardware. Die im Folgenden dargestellten Ergebnisse basieren auf der engen Zusammenarbeit zwischen der Ludwig-Maximilians-Universität München (LMU) sowie den Industriepartnern E.ON und Aqarios und kombinieren theoretische Grundlagenforschung mit anwendungsnahen Implementierungen.
Das Projekt war unterteilt in 9 Arbeitspakete (AP). AP1 war der Vorbereitung, der Problemanalyse und dem Start des Projekts gewidmet und AP9 diente dem Projektmanagement. Der restliche Bericht gibt einen Überblick über die von E.ON und Aqarios GmbH erarbeiteten Ergebnisse zu den Arbeitspaketen: AP2 (Intelligente Vorverarbeitungsmethoden), AP3 (Anwendungsfälle des zukünftigen Energienetzes, unterteilt in drei Use-Cases, UC1-3), AP4 (Benchmarking System), AP5 (Generalisierung und Wiederverwendung von Code) und AP6 (Skalierung auf Echtwelt-Problemgrößen), AP7 (Evaluation auf andere Domänen) und AP8 (Systemindustrialisierungsplan).

AP2: Intelligente Vorverarbeitungsmethoden

Neben den von der LMU entwickelten, allgemein anwendbaren Vorverarbeitungsmethoden, fokussierten wir uns (E.ON & Aqarios) auf Anwendungsfall-spezifische Vorverarbeitungsmethoden. Da diese Methoden jeweils zu den Anwendungsfällen, die in AP3 behandelt wurden, entwickelt wurden, werden diese auch im folgenden Kapitel detailliert beschrieben. Allgemein lassen sich diese Methoden allerdings zusammenfassend beschreiben als Zerteilungsalgorithmen. Das bedeutet, dass Sie aus einem großen Gesamtproblem mehrere kleinere Teilprobleme konstruieren. Eine weitere Gemeinsamkeit beruht darin, dass durch unsere intelligente Zerteilungsalgorithmen Nebenbedingungen direkt erfüllt werden können und somit nicht mehr durch Strafterme in die Teilprobleme integriert werden müssen.

AP3: Anwendungsfälle des zukünftigen Energienetzes

In diesem Teil des Berichts fassen wir die wesentlichen Forschungsergebnisse für die im Projektantrag spezifizierten Anwendungsfälle (AP3) zusammen. Im Zuge dessen beleuchten wir auch unsere Ergebnisse des intelligenten Vorverarbeitungsprogramms (AP2), Benchmarking-Systems (AP4) und der Evaluation auf Echtweltproblemen (AP6).

UC1: Dynamische Preisgestaltung zum Steuern von Verbrauchern

Paper: "Incentivizing Demand-Side Response Through Discount Scheduling Using Hybrid Quantum Optimization," IEEE Transactions on Quantum Engineering, vol. 5, pp. 1–15, 2024

Motivation

Die steigende Nachfrage nach Energieressourcen und die zunehmende Nutzung erneuerbarer Energiequellen erfordern innovative Lösungen zur Optimierung des Energieverbrauchs, um Netzüberlastungen zu reduzieren und CO_2-Emissionen zu senken. Demand-Side Response (DSR) ist eine vielversprechende Strategie, die sich auf die aktive Steuerung und Anpassung von Energieverbrauchsmustern durch Preisanpassungen als Reaktion auf Netzbedingungen konzentriert. Typischerweise wird DSR durch die Ausgabe eines dynamischen Preises an alle Kunden gleichzeitig erreicht. Aufgrund der unterschiedlichen Nutzungsmuster der Verbraucher ist das Ziel dieses Anwendungsfalls eine alternative, individuelle Preisgestaltung zu finden.

Problemformulierung

Für einen diskreten Zeithorizont von N_t Zeitschritten t und eine Menge von N_c Kunden c mit prognostizierten Verbrauchsdaten $d_{c,t}$ und der lokalen CO_2-Netzintensität I_t, besteht das Ziel des Discount Scheduling Problems (DSP) darin, jedem Kunden individuelle diskrete Rabatte $z_{c,t}$ zuzuweisen. Diese Rabatte (bzw. Aufschläge) sollen die Gesamtemissionen minimieren, während der Gesamtverbrauch konstant bleiben muss. Zudem müssen Netzbeschränkungen zu jedem Zeitpunkt erfüllt werden, das heißt an einem Zeitpunkt kann die maximale Abweichung des Verbrauchs nur innerhalb eines vorgegebenen Bereichs $\pm\Delta$ befinden. Ein weiterer Punkt, der durch unsere Formulierung garantiert gegeben sein muss und ist, ist, dass Kunden in allen Fällen von den gegebenen Anreizen profitieren, wenn sie diese befolgen.
Die zentrale Annahme des DSP ist, dass ein gegebener Rabatt (oder Aufschlag) die Kunden beeinflusst, ihren Verbrauch proportional zu ändern. Der neue Verbrauch wird demnach wie folgt berechnet:

$$\tilde{d}_{c,t} = (1 - \chi z_{c,t}) d_{c,t}$$

wobei χ die (negative) Preiselastizität der Nachfrage ist. Je höher χ ist, desto stärker reagieren die Kunden auf Preisanreize. Die mathematische Formulierung umfasst mehrere Komponenten:

1. Eine Kostenminimierungsfunktion für CO_2-Emissionen (Hauptziel): $\min_z \sum_{c,t} \tilde{d}_{c,t} I_t$
2. Strafen für Abweichungen vom Gesamtverbrauch pro Kunde (Nebenziel): $\min_z \sum_c \left(\sum_t d_{c,t} z_{c,t}\right)^2$
3. Strafen für aufeinanderfolgende Rabattänderungen (Nebenziel): $\min_z \sum_{c,t} \left(z_{c,t} - z_{c,t+1}\right)^2$
4. Eine L2-Regularisierung der Rabatte (Nebenziel und sehr gering gewichtet)
5. Harte Nebenbedingungen für die Gesamtverbrauchsabweichung und Leistungsbeschränkungen

$$\sum_{c,t} d_{c,t} z_{c,t} = 0 \qquad \left| \sum_{c} d_{c,t} z_{c,t} \right| \leq \Delta$$

Die Strafterme 2-4 werden alle individuell mit Vorfaktoren gewichtet, sodass das Hauptziel nicht vernachlässigt wird. Wir fixieren außerdem die möglichen diskreten Rabatt Stufen auf die folgenden Werte $z = -50\%, -25\%, 0\%, 25\%, 50\%$. Falls ein Lösungsalgorithmus ganzzahlige Variablen unterstützt, werden diese hier verwendet, andernfalls wird der Rabatt durch drei binäre Variablen enkodiert. Ähnliches gilt für die harten Nebenbedingungen, wenn diese nicht vom Algorithmus unterstützt werden: Sie müssen als Straf-Terme mit gegebenenfalls hohen Vorfaktoren in die Kostenfunktion integriert werden.

Problemzerteilungsmethode

Da das Problem mit steigender Kundenzahl schnell sehr groß wird (drei binäre Variablen pro Zeitschritt und Kunde), entwickelten wir eine spezielle Zerlegungsmethode. Sie dient als Vorverarbeitungsverfahren zur Zerkleinerung des gesamten Problems (AP2) und ermöglicht die Evaluation auf nahezu Echt-Welt Größen (AP6). Der Ansatz besteht aus mehreren Schritten und basiert auf der Erkenntnis, dass die harten Nebenbedingungen alle eine Summe über alle Kunden vorweisen:

1. Lösung eines globalen DSP mit kontinuierlichen Variablen ζ_t, in dem alle Kunden aufsummiert sind $D_t = \sum_c d_{c,t}$, das einen optimalen effektiven Rabatt für jeden Zeitschritt liefert (lineares Problem). Die Nebenbedingungen (5.) werden in der Optimierung mitbetrachtet.
2. Aufteilung der Kunden in Gruppen oder "Chunks"
3. Definition von Teilproblemen für jede Kundengruppe mit Ziel die diskreten Rabatte so zu vergeben, dass der effektive Rabatt reproduziert wird. Die Strafterme 2-4 werden in dieses Teilproblem mit aufgenommen.
4. Sequenzielle Lösung der Teilprobleme, wobei Fehler (keine Gleichheit der effektiven Rabatte) aus früheren Optimierungen in nachfolgende Teilprobleme einbezogen werden.
5. Zusammenführung aller Teillösungen und Anwendung einer Nachbearbeitungsroutine, um die Lösung zu verfeinern und sicherzustellen, dass keine Nebenbedingungen verletzt werden (Details: siehe Veröffentlichung).

Diese Zerlegungsmethode ermöglicht es, sehr große Probleminstanzen zu lösen, die mit allgemeinen Lösern nicht praktikabel wären, und ist speziell auf die Struktur des DSP zugeschnitten. Des Weiteren erlaubt sie die Anwendung von QUBO-basierten Lösungsalgorithmen da die harten Nebenbedingungen durch das globale DSP beachtet werden. Ein Überblick über die Routine verschafft folgende Grafik:

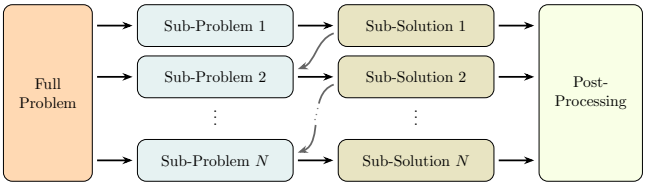

Benchmarks

Für die Benchmark-Experimente wurden synthetische Daten basierend auf realen Daten mit N_c von 25 bis 3200 Kunden und 76 Zeitschritten (entsprechend 15-Minuten-Intervallen über 19 Stunden) erstellt. Die CO_2- und Solardaten stammten vom 13. Januar 2023 aus dem Münchner Raum.

Für die Lösungsalgorithmus verwendeten wir als Stand-der-Technik den rein klassischen Gurobi-Solver, ein leistungsstarker, kommerzieller Branch-and-Bound MIP-Solver. Dieser wurde mit D-Wave's LeapHybridCQM-Solver verglichen, einem quantenklassischen Hybrid-Algorithmus, der über D-Wave's Cloud-Service zugänglich ist und klassische Algorithmen mit Quantenrechnern zur Lösung geeigneter Teilaufgaben kombiniert. Hinzu kamen unsere eigens entwickelten Zerlegungsmethoden (Decomp) mit Gurobi und Leap zur Lösung der Teilprobleme. In der Veröffentlichung werden zusätzlich kleinere Teilprobleme, die mittels QUBO-Heuristiken simuliertes Annealing (SA) und Quanten-Annealing (DW) durch D-Waves Hardware gelöst werden, untersucht.

Als Robuste Benchmarking Methode (AP4) haben wir jedem Solver die gleiche Zeit das Problem zu lösen gegeben (Zeit ist proportional zur Problemgröße) und am Ende die Lösungsqualität verglichen. Für die Zerteilungsmethode wurde diese Zeit gleichmäßig zwischen den Chunks aufgeteilt.

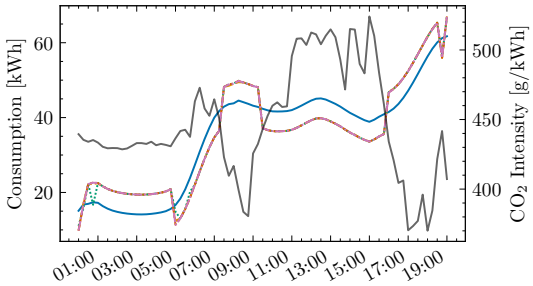

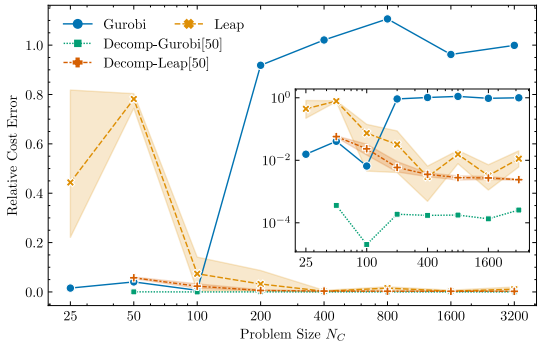

Die Ergebnisse zeigen links, die das optimierte Verbrauchsprofil im Vergleich zu der CO_2 Intensität (bei 100 Kunden) und rechts die Lösungsqualität in hinsichtlich dem relativen Kostenfunktionsfehler zur optimalen Lösung in Abhängigkeit von der Problemgröße (niedriger heißt besser, lineare und logarithmische y-Achse).
Auf der linken Seite sieht man klar, dass zu Zeitpunkten mit niedrigerem CO_2 Wert, der Verbrauch steigt und umgekehrt. Außerdem ist das Limit für die Abweichung vom Grund-Verbrauch deutlich ersichtlich. Für kleine Probleme ($N_c < 200$) liefert Gurobi gute Ergebnisse. Ab dieser Problemgröße beginnt Gurobi jedoch die interne Vorverarbeitung nicht mehr innerhalb der Zeitgrenzen beenden zu können und zeigt deshalb einen sprunghaften Anstieg der Metrik. Hier liefert der quantenunterstützte Leap die deutlich besseren Ergebnisse. Die Zerlegungsmethode übertrifft die allgemeinen Solver, insbesondere die rein klassische Gurobi-Variante, bei der Fehler konstant im Bereich von 10^{-4} liegt. Die Decomp-Variante von Leap überzeugt allerdings auch durch konsistentere Ergebnisse und leicht niedrigerem Fehler als Leap.
Als weitere Metrik haben wir die Fairness und Verteilung der Vergabe der Rabatte vergleichen. Dazu zeigen wir hier die Rabatt-Matrizen der unterschiedlichen Solver im 100 Kunden Fall. Rabatte werden in Blau angezeigt und Aufschläge in Rot.

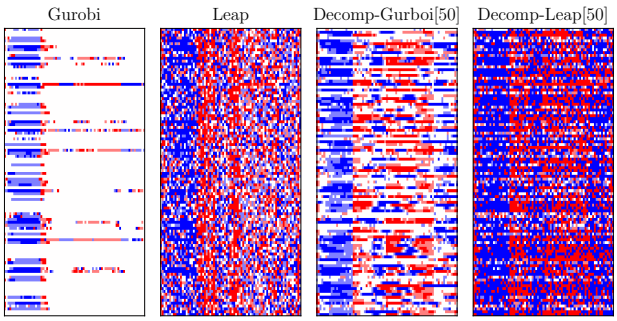

Hier ist ein deutlicher Unterschied zu erkennen: Gurobis Matrizen sind viel geregelter und im nicht Decomp Fall sogar fast überall Null. Währenddessen zeigen die Matrizen von Leap ein rauschendes Verhalten, in dem aber doch ein generelles Muster erkennbar ist, wann Rabatte und wann Aufschläge gegeben werden. Als wesentlichste Konsequenz lässt sich ableiten, dass Leap allen Kunden Rabatte verteil, diese also von der Methode profitieren (fair), währen Gurobi nur wenigen die Chance gibt zu profitieren (unfair).
Die Analyse in der Veröffentlichung unterstreicht diesen Punk noch an weiteren Metriken. Außerdem wird noch der Einfluss der Chunk-Größe untersucht mit dem Ergebnis: Größer ist besser, wenn der Solver das Problem lösen kann. Zusätzlich wurde gezeigt, dass die Decomp mit SA und DW besser Ergebnisse produziert als Leap.

Fazit

Die Untersuchung hat gezeigt, dass Quantencomputing-Techniken für die Lösung des DSP vielversprechend sind. Während der klassische Solver Gurobi bei kleinen Problemgrößen die besten Ergebnisse liefert, zeigt er ab einer bestimmten Größe deutliche Schwächen. Der quantenunterstütze Leap-Solver liefert weiterhin zufriedenstellende Ergebnisse, was auf einen potenziellen Vorteil bei der Lösung von Echtwelt-Problemgrößen (>1000 Kunden, AP8) hindeutet. Es muss allerdings erwähnt sein, dass D-Wave nicht veröffentlicht, wie viel

Quanten-Computing in ihrem hybriden Solver verwendet wird.
Unsere entwickelte problemspezifische Zerlegungsmethode (AP2) in Verbindung mit dem klassischen Solver lieferte jedoch die besten Ergebnisse über alle untersuchten Problemgrößen.
Für die Zukunft könnten die Kombination der Zerlegungsmethode mit Leap bei großen Chunk-Größen und die Weiterentwicklung der direkten Quantencomputer-Implementierungen vielversprechende Wege sein, um das volle Potenzial von Quantencomputern für diesen Anwendungsfall zu nutzen.

UC2.1: Dynamische Identifikation autarker Energiegemeinschaften

Paper: "Evaluating Quantum Optimization for Dynamic Self-Reliant Community Detection," IEEE Transactions on Smart Grid, vol. 16, no. 2, pp. 1339–1350, Mar. 2025

UC2 wurde in zwei Teilen untersucht, welche mit verwandten Algorithmen bearbeitet wurden. Der erste Teil beschäftigt sich mit autarken Energie-Gemeinschaften, der zweite Teil mit optimalen Koalitionen von Prosumern.

Motivation

Mit der zunehmenden Integration erneuerbarer Energien im Stromnetz vollzieht sich ein Wandel von zentraler Planung hin zu dezentraler, lokaler Stromerzeugung. In einem solchen zukünftigen Stromnetz werden die Planungsperioden deutlich kürzer, da die Erzeugungsseite schwankend ist und große Verbraucher wie Elektrofahrzeuge oder Wärmepumpen dynamisch zu- und abgeschaltet werden. Die Aufteilung des Netzes in virtuelle Microgrids unterstützt Analyse- und Verwaltungsaufgaben, verbessert den Energieausgleich und erhöht die Speichernutzung. Besonders mit wachsender dezentraler Stromerzeugung können logische Cluster helfen, das proaktive Verhalten einzelner Kunden zu fördern, da die Interaktion nicht zwischen Kunden und Netzbetreiber, sondern zwischen Kunden innerhalb derselben Gemeinschaft stattfindet.

Problemformulierung

Für diesen Anwendungsfall haben wir eine Erweiterung zum bekannten kombinatorischen Optimierungsproblem der Community Detektion für Graphen-Partitionierung entwickelt: Das Self-Reliant Community Detection (SRCD) Problem, identifiziert selbstversorgende virtuelle Mikronetze, also Partitionen von lokalen Erzeugern und Verbrauchern, bei denen Erzeugung und Verbrauch nahezu ausgeglichen sind. Dies wird zudem erweitert, indem der momentane Leistungsfluss in die Community-Detektions-Formulierung einbezogen wird.
Zur mathematischen Formulierung modellieren wir das lokale Stromnetz als Graph mit N Knoten: Jeder Knoten i entspricht einem Erzeuger oder Verbraucher, je nachdem ob p_i positiv oder negativ ist. $|p_i|$ ist dabei die verbrauchte oder erzeugte Leistung. Die Kanten entsprechen den Stromleitungen, weshalb als nächster Schritt eine DC-Stromfluss Simulation gemacht wird, um herauszufinden wie viel Strom $w_{i,j}$ über Kante (i,j) fließt.
Für die Formulierung muss die Anzahl an maximal möglichen Gemeinschaften auf K begrenzt werden. Dann lässt sich jede Community durch K binäre Variablen One-Hot enkodieren. Das heißt innerhalb der K Variablen ist immer nur eine auf Eins gesetzt, die andere sind Null, die Position der Einser Variable entspricht dann der enkodierten Gemeinschaft. Insgesamt werden jedem Knoten K binäre Variablen zugeordnet, um jeden Knoten jeder Gemeinschaft zuzuordnen. Die folgende Abbildung visualisiert das Vorgehen des SRCD-Problems:

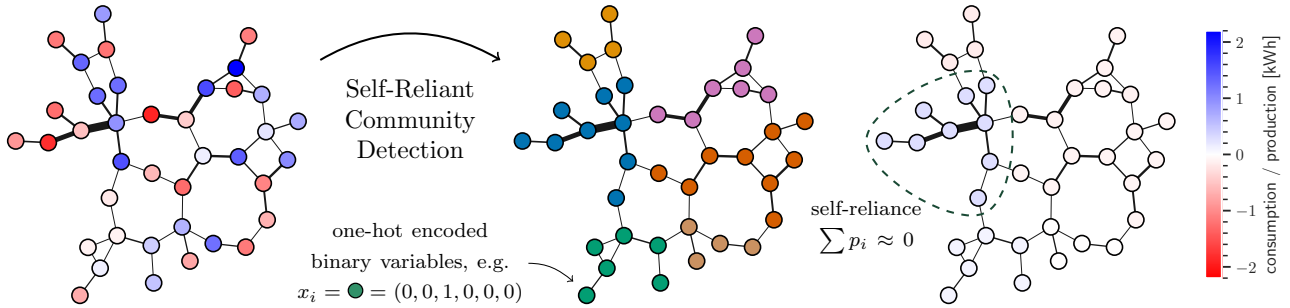

Die Kostenfunktion für die Optimierung setzt sich aus zwei Teilen zusammen: Dem Community-Detektions-Teil und dem Selbstversorger-Teil:

1. Community-Detektion: Die Maximierung der Modularität maximiert die Verbindungen innerhalb von Gemeinschaften im Verhältnis zu Verbindungen zwischen Gemeinschaften.

$$\max_x \frac{1}{2m}\sum_{i,j}\left(w_{i,j}-\frac{k_i k_j}{2m}\right)\sum_k x_{i,k}x_{j,k} \qquad \text{mit } k_i=\sum_j w_{i,j} \text{ und } m=\frac{1}{2}\sum_i k_i$$

2. Selbstversorgungsstrafe: Minimiert die quadratische Abweichung der Nettoleistung (Erzeugung minus Verbrauch) in jeder Gemeinschaft.

$$\min_x \sum_k \left(\sum_i p_i x_{i,k}\right)^2$$

Die Zielfunktion ist dann eine Kombination der beiden Terme mit Vorfaktor für den Selbstversorger-Teil. Somit ist das Optimierungsproblem quadratisch und binär. Allerdings muss die One-Hot Enkodierung eingehalten werden: $\sum_k x_{i,k} = 1\ \forall i$. Das bedeutet, eine QUBO-Formulierung muss einen weiteren Strafterm zur Kostenfunktion hinzufügen. Ähnlich wie in UC1 haben wir aber auch hier eine hybride Heuristik entwickelt, die diese Strafterme vermeidet und die obige Nebenbedingung immer einhält (AP2).

Problemzerteilungsmethode

Da aktuelle Quantenhardware nur begrenzte Anzahl an Qubits und Konnektivität bietet, haben wir ein hierarchischen divisiven Hybrid-Quantenalgorithmus entwickelt, der das Netzwerk rekursiv teilt, indem er kleinere QUBO-Teilprobleme löst. Diese Methode ist vom GCS-Q Algorithmus zur Lösung kollaborativer spieltheoretischer Modelle mittels Quantenrechner inspiriert. Der Ansatz beginnt damit, alle Knoten in derselben Gemeinschaft zu platzieren, und teilt sie iterativ, bis keine weitere Verbesserung mehr möglich ist. Da jedes der Teilprobleme nur eine Teilung des aktuellen Netzes vornimmt, kann auf die One-Hot Enkodierung verzichtet werden, somit wird das Teilproblem formuliert durch

$$\min_{\mathrm{x}} \frac{-1}{2m}\sum_{i,j}\left(w_{i,j}-\frac{k_i k_j}{2m}\right)(2x_i x_j - x_i - x_j + 1) + \lambda\left(\sum_i p_i x_i\right)^2 + \lambda\left(\sum_i p_i(1-x_i)\right)^2$$

Die Zerteilungs-Methode bietet einige Vorteile. Als Erstes lässt sich hier die Reduzierung der QUBO-Matrix-Größe um den Faktor K im Vergleich zum Einzelproblem-QUBO nennen. Nicht nur das, aber jedes Folgeproblem schrumpft bei jeder Iteration ungefähr um den Faktor zwei. Aus diesem Grund erweitern wir den Algorithmus, indem wir ab einer bestimmten Teilproblem-Größe (20) klassische Methoden zur Lösung einsetzen. Diese finden die optimale Teilung in vernachlässigbarer Zeit. Der zweite Vorteil ist, dass im Vorhinein die Anzahl an Gemeinschaften nicht bekannt sein muss.
Jedoch birgt der Ansatz auch Nachteile: Eine optimale Teilung bei jedem Subproblem führt nicht unbedingt zur optimalen Lösung des SRCDs, der Algorithmus ist nämlich eine „gierige“ Heuristik. Zudem müssen insgesamt mindestens $2K-1$ Teilprobleme gelöst werden, bei K gefundenen Gemeinschaften. Letzteres Problem kann allerdings durch das Einsetzen klassischer Methoden ab Größe 20 deutlich abgeschwächt werden.

Benchmarks

Für die Evaluierung des Verfahrens wurden IEEE-Standard-Testfälle mit Größen von 39 bis 1888 Knoten herangezogen, die folgendermaßen angepasst wurden, um Verteilungsnetze besser darzustellen: Größe wurde skaliert, die Stromleitungen wurden ausgetauscht und die Spannung wurde im gesamten Netz auf 400V gesetzt. Um realistische Szenarien zu simulieren, wurden auf den Netzwerkknoten zufällig Erzeuger und Verbraucher platziert, deren Erzeugungs- und Verbrauchsdaten aus verschobenen Normalverteilungen entnommen wurden. Für statistische Relevanz wurden für jeden Netzwerktestfall fünf verschiedene Instanzen mit unterschiedlichen Zufallsstartwerten (Seeds) generiert.
Unterschiedliche Solver wurden beim Benchmarking verglichen: Auf klassischer Seite kamen der kommerzielle Branch-and-Bound-Solver Gurobi, ein für das SRCD angepasster Louvain-Algorithmus (bekannte Community-Detektions Heuristik) sowie die heuristischen Verfahren simuliertes Annealing (SA) und QBsolv mit SA (QSA) zum Einsatz. Als hybride Quantenlöser wurden D-Wave's Cloud-basierte Dienste genutzt: Der Leap hybrid CQM Solver für die direkte Lösung und der Leap hybrid BQM Solver für die iterative Lösung. Für reine

Quantenberechnungen wurde direkt auf D-Wave's Quantum Annealing Prozessor Advantage 5.4 zurückgegriffen (DW).
Als Metrik wurde die Relative Lösungsqualität verwendet, welche die Lösungsenergie mit der besten gefundenen Lösung über alle Solver vergleicht (eins bedeutet beste gefundene Lösung). Wir betrachten die Lösung des gesamten Problems und die iterative Lösung mit dem Zerteilungsalgorithmus separat. Jeder Algorithmus wird fünfmal ausgeführt und bekommt ein Zeitlimit von 6s im Gesamtproblem-Fall und 3s pro Teil-Problem im iterativen Fall.
Die nachfolgenden Plots zeigen die Ergebnisse für das Gesamtproblem (links), für den iterativen Algorithmus (rechts oben) und den Vergleich zwischen iterativ und gesamt (rechts unten) für Netzwerke bis 300 Knoten.

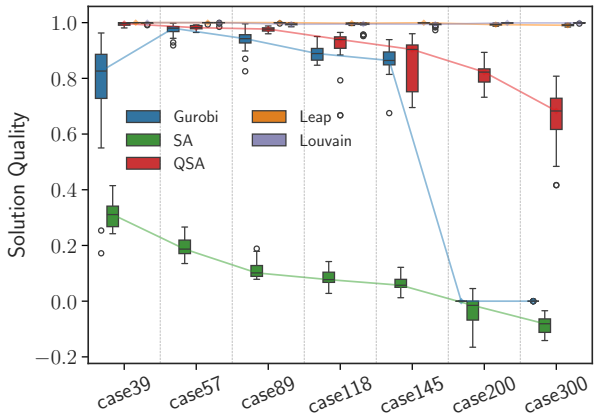

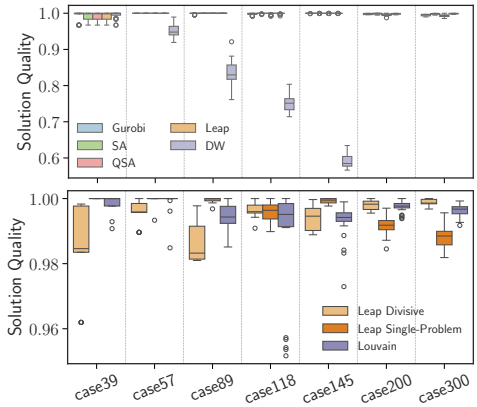

Die Louvain-Methode und Leap erzielten die beste Lösungsqualität. QSA verliert an Güte mit zunehmender Problemgröße. Gurobi hingegen weist wieder einen sprunghaften Verfall der Lösungsqualität auf, wie schon in UC1 beobachtet. SA schneidet sehr schlecht ab, was höchstwahrscheinlich an den Einzelbitflip-Updates liegt, die wegen der One-Hot Enkodierung verboten sind. Betrachten wir hingegen die Ergebnisse des iterativen Algorithmus, sehen wir, dass alle Methoden eine sehr gute Lösungsgüte aufweisen, bis auf DW. DW verliert schnell an Lösungsqualität je größer das Problem wird. Ein Grund dafür ist, dass die Teil-Probleme vollvermascht sind und die Einbettung der Problemtopologie in die Hardwaretopologie immer mehr Qubits zu „Ketten“ zusammenschließen muss. Durch Rauschen der aktuellen NISQ-Hardware führt das bei langen Ketten wiederum zu „Kettenbrüchen“ und, damit einhergehend, schlechteren Ergebnissen.
Die vier guten Methoden wurden in der Veröffentlichung noch weiterhin auf den größeren Probleminstanzen bis 1888 Knoten getestet. Dabei wurde aber nur das erste Teilproblem untersucht und es hat sich gezeigt, dass Leap die beste Lösungsqualität hält (gefolgt von SA, Gurobi, QSA).
Vergleich man nun final die Lösungsqualität von iterativ und gesamt, sehen wir das Leap im Gesamtproblem mit zunehmender Größe schlechter wird, während der iterative besser wird. Allenfalls ist immer eine leicht bessere Qualität als mit Louvain zu verzeichnen

Fazit

Die Untersuchung hat gezeigt, dass quantenunterstützte Lösungstechniken wettbewerbsfähige Ergebnisse im Vergleich zu rein klassischen Methoden zur Lösung des hier entwickelten SRCD-Problems liefern können. Obwohl NISQ-Quantenhardware noch nicht in der Lage ist, diese Art von Problemen zuverlässig nur mit Quantenressourcen zu lösen, kann D-Wave‘s hybrider Leap Algorithmus jetzt schon klassische Methoden übertreffen. Besonders der in diesem Kontext entwickelte hybride Aufteilungsalgorithmus, der iterativ kleinere Teil-QUBO-Probleme löst, liefert deutlich bessere Ergebnisse als das Lösen des Gesamtproblems. Insgesamt ist SRCD ein durchaus möglicher Anwendungsfall für den Einsatz von QC für den Betrieb zukünftiger Energienetzte.

UC2.2: Finden Optimaler Koalitionen in Dezentralisierten Netzen

Paper: [“A Competitive Showcase of Quantum versus Classical Algorithms in Energy Coalition Formation,” May 20, 2024, arXiv Preprint]

Motivation

Für die Erzeugung von Energiegemeinschaften bietet die kooperative Spieltheorie einen Rahmen, um zu

verstehen, wie Prosumer Koalitionen bilden können, um ihren kollektiven Nutzen zu optimieren. Innerhalb dieser Methodik bezeichnet eine Koalitionsstruktur die Einteilung von Akteuren in Gruppen, die mit C bezeichnet werden. Die Koalitions-Spiel lässt sich durch eine charakteristische Funktion beschreiben, typischerweise dargestellt als $v(C)$, welche den verschiedenen Koalitionen Werte zuweist. Diese spezielle Art kooperativen Spiels, das durch eine charakteristische Funktion definiert ist, wird üblicherweise als *„Characteristic Function Game“* (CFG) bezeichnet.
Die Wertfunktion liefert eine Maßzahl für den kooperativen Vorteil bzw. den Vorteil, die die Mitglieder einer Koalition durch Zusammenarbeit – im Vergleich zum unabhängigen Handeln – erzielen können.
Das Problem, die optimale Koalitionsstrukturen zu finden, ist äußerst anspruchsvoll – insbesondere bei n Akteuren, da es insgesamt $\mathrm{O}(\mathrm{n}^{\mathrm{n}})$ mögliche Partitionen gibt. Derzeit ist der beste Algorithmus, der eine optimale Lösung mit vertretbarem Rechenaufwand finden kann, ein Dynamic Programming-Algorithmus, der dies in $O(3^n)$ Zeit erreicht.
Ein CFG kann in ein annähernd äquivalentes Spiel überführt werden, ein *„Induced Subgraph Game“* (ISG). In dieser Graph-Darstellung entsprechen die Knoten den Akteuren, und die Koalitionswerte werden durch paarweise Interaktionen in einem gewichteten Graphen abgebildet, sodass gilt:

$$v(C_l) = \sum_{(i,j)\in C_l} w_{ij} \,,$$

wobei w_{ij} die Kantengewichte im Graphen sind. Die Transformation eines CFG in ein ISG ermöglicht es, das Problem als Quadratic Unconstrained Binary Optimization (QUBO) neu zu formulieren, was effizientere Lösungsansätze erlaubt. Es ist jedoch wichtig zu beachten, dass das QUBO-Problem weiterhin NP-schwer bleibt. In Teilprojekt haben wir eine neuartige Formulierung der Bildung von Energiegemeinschaften formuliert, in dem genau der Ansatz des ISG gewählt wurde.
Unsere Analyse umfasste ein Benchmarking von Quantum Annealing auf D-Wave-Hardware sowie dem Quantum Approximate Optimization Algorithm (QAOA) auf IBM-Hardware, und den Vergleich zu klassischen Lösungsverfahren wie Gurobi, Tabu-Suche, Simulated Annealing und QB-solve. D-Wave wies gegenüber klassischen approximativen Lösungsverfahren einen Skalierungsvorteil beim Finden näherungsweiser Lösungen auf und übertraf QAOA auf IBM-Hardware.

Problemformulierung

Betrachten wir ein Verteilnetz mit N Prosumern, die jeweils über teilweise flexible Lasten, Photovoltaikanlagen und/oder Speicher verfügen. Individuelle Stromverträge mit zeitlich variablen Tarifen führen dazu, dass jeder Prosumer versucht, seine eigenen Energiekosten mithilfe flexibler Ressourcen und unter bestimmten Einschränkungen zu senken. Dieses Modell fördert autarkes Handeln und verringert die Stromabnahme aus dem Netz. Allerdings fehlt die Koordination zwischen verschiedenen Prosumer-Gruppen. Eine Alternative besteht in einem gemeinschaftlichen Ausgleich von Angebot und Nachfrage, modelliert durch ein kollektives Energiemanagement-Problem.
Die Prosumer werden in Koalitionen aufgeteilt, mit dem Ziel, die Summe der den Koalitionen zugewiesenen Werte zu maximieren. Die Entscheidungsvariable x_l gibt an, ob die Koalition C_l für die finale Koalitionssturktur ausgewählt wird, unter Einhaltung bestimmter Nebenbedingungen. Die Zielfunktion berechnet den Wert jeder Koalition in Bezug auf reduzierte Netzbetriebskosten. Das Entscheidungsproblem des Verteilnetzbetreibers (DSO) besteht somit darin, die Prosumer in eine Menge netzgemessener Koalitionen zu partitionieren, mit dem Ziel, die Netzbetriebskosten zu minimieren.

$$\begin{aligned} \max_{x_l, l\in[2^n-1]} & \sum_{l\in[2^N-1]} v(C_l)x_l, \\ \text{s.t.} & \sum_{j\in[2^N-1]} S_{il}x_l = 1, \forall i \in [N], \\ & x_l \in \{0,1\}, \forall l \in [2^N-1]. \end{aligned}$$

Hierbei ist zu beachten, dass es $2^N - 1$ mögliche Teilkoalitionen von Prosumern gibt. Es gilt $S_{il} = 1$, wenn Prosumer $i \in [N] = \{1,2,\dots,N\}$ zur Koalition (C_l) gehört (d.h. $i \in C_l$), und $S_{il} = 0$ andernfalls. Diese Formulierung ist

sehr rechenintensiv, da die Anzahl der binären Entscheidungsvariablen von der Anzahl möglicher Teilkoalitionen abhängt, die exponentiell mit der Anzahl der Prosumer wächst (also $2^N - 1$). Diese CSG-Formulierung kann in ISG überführt werden, wie oben bereits beschrieben.
Da die Wertfunktion $v(C_l)$ in unserem Fall nichtlinear ist, ist das ISG-Modell nicht direkt auf unser CSG-Problem anwendbar. Dennoch können wir ein ISG auf Basis paarweiser gemeinsamer Nutzenwerte $\bar{w}_{i,j}$ nutzen, um unser CSG näherungsweise darzustellen. Das folgende quadratische Optimierungsproblem kann verwendet werden, um paarweise Gewichte zu bestimmen, die den mittleren quadratischen Fehler zwischen den ursprünglichen Wertfunktionen und ihrer ISG-Näherung minimieren.

$$\min_{\bar{w}_{\{i,j\}}^{i,j\in[N]}} \sum_{l\in[2^N-1]} \left(v(C_i) - \sum_{(i,j)\in C_1} \bar{w}_{ij} \right)^2$$

Ähnlich zu dem in UC2.1 untersuchten verfahren, kann ausgehend von der Gesamtheitskoalition eine Näherungslösung für das ISG durch iteratives Aufteilen von Koalitionen in zwei Teilgruppen gefunden werden, bis keine besseren Zerteilungen mehr möglich sind. Sei C eine der gefundenen Teilmengen in einer beliebigen Iteration, dann kann die Unterteilung von C in der nächsten Iteration mittels der folgenden QUBO mit N binären Entscheidungsvariablen bestimmt werden:

$$\min_{x_i, i\in C} \sum_{i\in[N]} \sum_{j\in[N]\setminus i} \bar{w}_{ij} x_i (1 - x_j).$$
$$\text{s.t. } x_i \in \{0,1\}, \forall i \in [N].$$

Benchmarks

Approximative Optimierung ist insbesondere für industrielle Anwendungsfälle von entscheidender Bedeutung, bei denen eine Echtzeitoptimierung erforderlich ist – hier ist das schnelle Finden hochwertiger Lösungen oft wertvoller als das langsamere Erreichen exakter Lösungen. Als Quanten-Lösunsgsansätze verwenden wir den Quantenannealer von D-Wave sowie QAOA auf IBM-Hardware. Unsere klassischen Löser umfassen Tabu-Suche, Simulated Annealing und Gurobi.

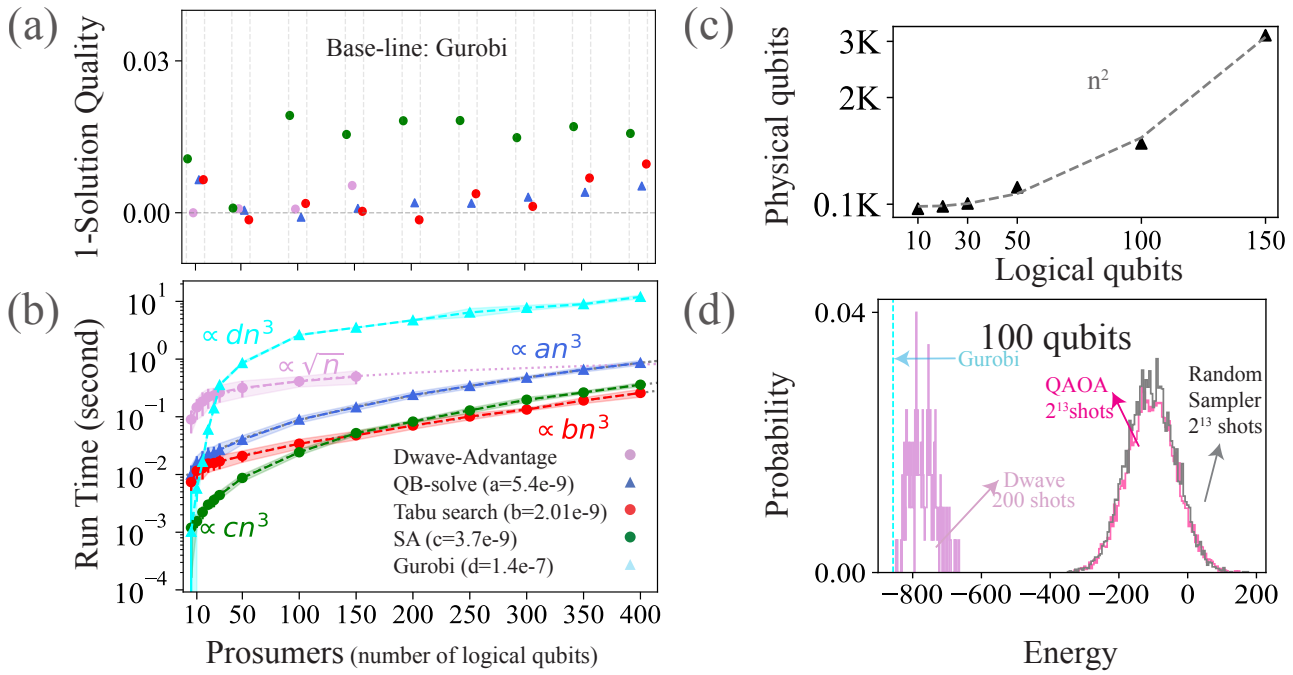

Benchmarking classical solvers against DWave in energy coalition formation for randomly generated problem instances. (a) The solution quality versus the number of prosumers. (b) Run time versus number of prosumers. (c) The number of physical qubits versus logical qubits (number of prosumers) on DWave hardware for the first split of the grand coalition into two partitions. Note that results for each number of prosumers showcase averages across

20 realizations. (d) Energy distribution sampled from DWave, QAOA, and a random sampler for the first split of the grand coalition to two partitions for a randomly generated instance with 100 prosumers (100 qubits). The dashed vertical line shows the solution found by Gurobi.

Hinsichtlich der Lösungsqualität findet D-Wave bei Problemgrößen bis zu 150 Prosumern – der größten auf der Hardware getesteten Instanz – durchgehend Lösungen, die denen von Gurobi ähnlich sind, mit Ausnahme des Falls mit 150 Prosumern, bei dem die Lösung von D-Wave um 1% suboptimal ist. Innerhalb dieses Bereichs an Prosumern findet Tabu Suche durchgehend Lösungen, die entweder leicht besser oder schlechter als die von Gurobi sind, mit einer Abweichung von weniger als 1%. Für Instanzen mit über 200 Prosumern, für die keine Ergebnisse von D-Wave vorliegen, identifiziert Gurobi durchgehend die beste Lösung unter den klassischen Lösern. Alle Lösungsalgorithmen übertreffen Simulated Annealing (SA).

Bezüglich der Laufzeit zeigt D-Wave eine günstigere Skalierung in Abhängigkeit von der Problemgröße, wie in Abbildung (b) dargestellt. Die Laufzeiten von Gurobi, QB-Solve, Tabu-Suche und Simulated Annealing skalieren kubisch mit unterschiedlichen Vorfaktoren, wobei Tabu Search den kleinsten Vorfaktor aufweist. Im Gegensatz dazu skaliert die Laufzeit von D-Wave mit $\sqrt{N}$.

Bei der Nutzung des D-Wave-Quantenannealers zur Lösung eines Problems muss die Konnektivität der logischen Qubits im Problem auf den Konnektivitätsgraphen der Hardware abgebildet werden, der bei den Advantage-Quantenprozessoren auf der Pegasus -Topologie basiert. Dieser Abbildungsprozess erfordert in der Regel zusätzliche Qubits, sogenannte physikalische Qubits, die über die in der ursprünglichen Problemstellung benötigten hinausgehen. Abbildung (c) zeigt die Skalierung der physikalischen Qubits in Abhängigkeit von der Anzahl der logischen Qubits (Prosumern).

Abbildung (d) zeigt die Energiedistribution (für eine zufällig generierte Instanz mit 100 Prosumern), die mit QAOA (mit Q-Ctrl FireOpal Fehlerunterdrückung), D-Wave und einem zufälligen Sampler erzeugt wurde. Die vertikale cyanfarbene Linie markiert die von Gurobi gefundene Lösung, deren Optimalität jedoch nicht bewiesen ist. Bemerkenswert ist, dass D-Wave dieselbe Lösung findet, während die QAOA-Verteilung der des zufälligen Samplers stark ähnelt. Die Schaltungstiefe für QAOA in diesem Experiment, unter Anwendung des Fireopal-Transpilers, beträgt 11k.

Fazit

Die Erzeugung von Energiegemeinschaften stellt einen entscheidenden Schritt in Richtung einer dezentralen und nachhaltigen Energieverwaltung dar. In diesem Teilprojekt haben wir eine Methodik vorgestellt, das Problem als CSG zu formulieren, um zu verstehen, wie Prosumer sich am besten zu Koalitionen zusammenschließen können, um ihre kollektiven Vorteile zu maximieren.

Wir stellen außerdem eine neuartige Methode vor, mit der sich diese Formulierung in ein QUBO-Format überführen lässt. Unsere Ergebnisse zeigten, dass die D-Wave-Hardware in Bezug auf die Lösungsqualität einen den QAOA-Ansatz auf IBM-Hardware übertrifft.

D-Wave weist zudem eine günstigere Zeitskalierung in Abhängigkeit von der Problemgröße auf als klassische Heuristiken. Für die von uns betrachteten Systemgrößen bleibt D-Wave jedoch langsamer als einige klassische Methoden wie etwa QB-Solve. Hinsichtlich der Lösungsqualität erreicht D-Wave das Niveau unserer besten klassischen Löser (z. B. Gurobi und Tabu Suche) für bis zu 100 Prosumer und erzielt Lösungen mit einer 1% Abweichung vom Gurobi Ergebnis bei Problemen mit 150 Prosumer.

UC3: Netzkostenverteilung in P2P Energiemärkten

Paper: "Grid Cost Allocation in Peer-to-Peer Electricity Markets: Benchmarking Classical and Quantum Optimization Approaches," presented at the Workshop on Quantum Artificial Intelligence and Optimization 2025, Jul. 2025, pp. 751–762.

Motivation

Die zunehmende Verbreitung von dezentralen Energieressourcen und die Transformation von Stromverbrauchern zu Produzenten und Konsumenten (Prosumern) treibt grundlegende Veränderungen im Betrieb von Stromsystemen voran. Peer-to-Peer (P2P) Strommärkte haben sich als vielversprechendes Paradigma etabliert, um direkten Energiehandel zwischen Prosumern zu ermöglichen und gleichzeitig die Netzstabilität und Betriebseffizienz aufrechtzuerhalten. Eine zentrale Herausforderung bei der Implementierung von P2P-Märkten liegt in der gerechten Zuweisung von Netzbetriebskosten an die Teilnehmer basierend auf ihrer tatsächlichen Infrastrukturnutzung. Konstante Netztarife sind in P2P-Umgebungen unzureichend, da sie die komplexen

Leistungsflüsse nicht berücksichtigen. Daher behandelt dieser Anwendungsfall einen dynamische Kostenzuweisungsmechanismus mithilfe eines Optimierungsproblems.

Problemformulierung

Wie in UC2 wird das Stromnetz wird als Graph $G(V,E)$ modelliert, wobei Stromleitungen als Kanten E und Produzenten oder Konsumenten als Knoten $i \in V = P \cup C$ dargestellt werden (P und C sind die Mengen der Erzeuger bzw. Verbraucher). Jeder Knoten hat eine Verbrauchs-/Erzeugungsleistung d_i. Ziel ist es, eine Zuordnung $z = \{(p_i, c_j), (p_k, c_l), \dots\} \subseteq P \times C$ zu finden, bei der die Überlappung aller Paarleistungsflüsse von z – genannt logischer Leistungsfluss – dem physikalischen Leistungsfluss entspricht. Der physikalische Leistungsfluss ergibt sich wie in UC2 durch DC-Stromfluss-Simulation. Ebendiese kann auch verwendet werden, um die Paarleistungsflüsse zu berechnen, bei nur Produzent p und Konsument c aktiv sind und alle anderen Teilnehmer inaktiv sind. Der Paarleistungsfluss gibt uns an welche Stromtrassen zu welchem Grad benutzt werden, wenn p und c einen Handel eingehen. Das bedeutet im Vorfeld des Optimierungsproblems wird der Paarleistungsfluss für jedes mögliche Paar berechnet $v_{i,j}^{p,c}$ sowie der physikalische Leistungsfluss $w_{i,j}$. Jedes Paar bekommt eine binäre Variable $x_{p,c}$, welche die Zuordnung z enkodiert. Damit lässt sich das Leistungsfluss-Anpassungsproblem definieren

$$\min_x \sum_{i,j} \left(\sum_{p,c} x_{p,c} v_{i,j}^{p,c} - w_{i,j} \right)^2 ,$$

ein binäres kleinste Quadrate Problem. Die Lösung gibt an, welche Kunden handeln müssen, damit der monetäre Fluss auch dem physikalischen Stromfluss entspricht. Die Abbildung auf der rechten Seite zeigt in (a) den physikalischen Leistungsfluss und in (b) die Diskrepanz zwischen logischem und physikalischem Leistungsfluss, wenn die eingezeichneten Paare handeln.

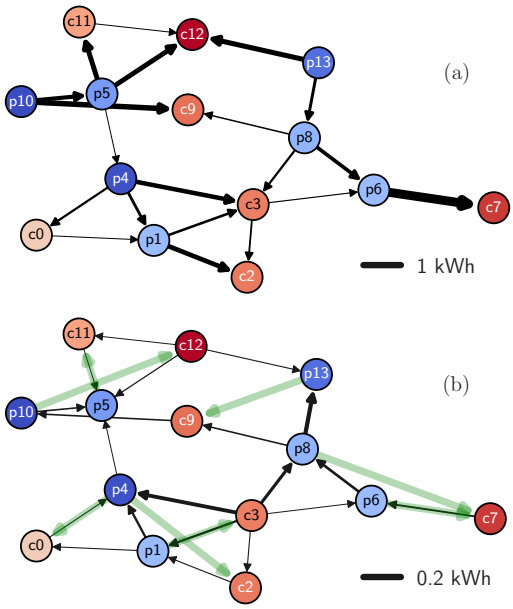

Die Kostenzuweisung erfolgt dann folgendermaßen: Jeder Leistungsfluss über eine Stromleitung kostet beide Handelspartner gleichermaßen. Logischer Fluss entgegengesetzt physikalischem wird nicht berechnet, da dieser effektiv Belastung aus einer Leitung herausnimmt. Formalisiert sind die Kosten für einen Konsumenten (Produzent analog)

$$\frac{\rho}{2} \sum_p x_{p,c} \sum_{i,j} u_{i,j} \left[v_{i,j} \operatorname{sign}(w_{ij}) \right]^+ ,$$

wobei $[\cdot]^+ = \max\{0,\cdot\}$. Die Formulierung umfasst des Weiteren ein Auslastungsfaktor $u_{i,j} = |w_{i,j}|/W$ der angibt, wie stark eine Stromtrasse, die verwendet wird, insgesamt belastet ist, und damit die abgerechneten Kosten skaliert.

Für das gesamte Optimierungsproblem integrieren wir die Kostenallokation von allen Teilnehmern zusätzlich in die Zielfunktion des Leistungsfluss-Anpassungsproblems, um nur die Zuweisungen zu finden die auch günstig für die Kunden, also in deren Interesse, sind. Dazu wird der Leistungsfluss-Teil noch mit einem zusätzlichen Vorfaktor versehen, der so gewählt wird, dass dieser Teil immer noch das Haupt-Ziel der Optimierung bleibt.

Dieses Problem ist bereits in QUBO-Form, sodass keine zusätzlichen Transformationen erforderlich sind, um Quantenoptimierungsmethoden anzuwenden. Das ist in diesem Fall eine Besonderheit, die sonst selten vorkommt. Darum wird auch keine weitere Problemzerlegungsmethode getestet.

Unsere Veröffentlichung zu diesem Anwendungsfall beinhaltet eine Fallstudie, die klar zeigt, dass die Kostenallokationsmethode alle Netzbetriebskosten decken kann und insgesamt billiger für Konsumenten, bzw. lukrativer für Produzenten ist.

Benchmarks

Die numerischen Experimente erfolgten auf IEEE-Testfällen mit 9 bis 57 Knoten, die nach demselben Muster

angepasst wurden wie in UC2 beschrieben. Für jeden Testfall wurden 20 Instanzen mit unterschiedlichen Verbrauchsprofilen erstellt. Der Netzgebührenparameter ρ wurde für jeden Testfall so festgelegt, dass der Netzbetreiber etwa 80% der Basiskosten erhält.
Als klassischer Lösungsmethode wurde wieder Gurobi als kommerzieller MIP Solver verwendet. Hierfür wurden jedoch zwei Formulierungen untersucht: Neben der bekannten QUBO-Form [ncvx], wurde außerdem eine spezielle Formulierung des Problems implementiert. Das kleinste Quadrate Problem ist konvex, daher lässt sich die Zielfunktion nur durch die Abweichungen ausdrücken: $\min_x \sum_{i,j} r_{i,j}^2 \text{ s.t. } r_{i,j} = \sum_{p,c} x_{p,c} v_{i,j}^{p,c} - w_{i,j}$. Diese Formulierung ermöglicht Gurobi eine effizientere Suche nach der optimalen Lösung.
Neben Gurobi wurden die bekannten QUBO-Heuristiken simuliertes Annealing (SA) und Tabu-Suche (TS) verwendet. Von D-Wave wurde direktes Quanten-Annealing mit Advantage 5.4, sowie hybride Lösung Mithilfe von Leap hybrid BQM, getestet. Da die QUBO vollvermascht ist, wurde sogenanntes Clique-Embedding verwendet, eine effiziente Methode vollständige Graphen in die D-Wave Topologie einzubetten. Die Hyperparameter für die klassischen Heuristiken und das D-Wave QA wurden im Vorfeld der Benchmarks optimiert.
Zwei Bewertungsstrategien wurden angewandt:

1. Lösungsqualität innerhalb eines Zeitlimits: Für jeden Testfall wurde ein mit der Problemgröße wachsendes Zeitlimit gesetzt (siehe UC1, UC2, AP4) und untersucht, wie nahe gefundene Lösungen an der optimalen Lösung liegen, gemessen durch den relativen Zielfunktionsfehler.
2. Time-to-Solution (TTS): Erwartete Zeit, die jeder Solver benötigt, um eine Lösung ausreichender Qualität zu erreichen, definiert als innerhalb von 5% der optimalen Lösung. Die Berechnung erfolgt durch die benötigte Zeit eine Lösung zu produzieren zusammen mit den erwarteten Wiederholungen des Algorithmus basierend auf der Wahrscheinlichkeit eine ausreichende Lösung zu finden.

Die nachfolgenden Grafiken zeigen die Ergebnisse für die Lösungsqualität auf der linken Seite und die TTS auf der rechten Seite. Die 5% Fehler-Linie für ausreichende TTS-Lösungen ist links mit eingezeichnet.

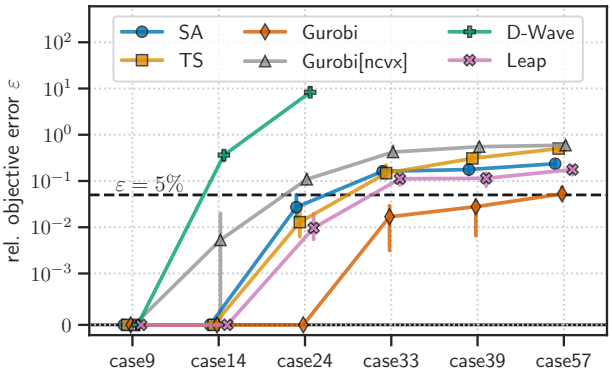

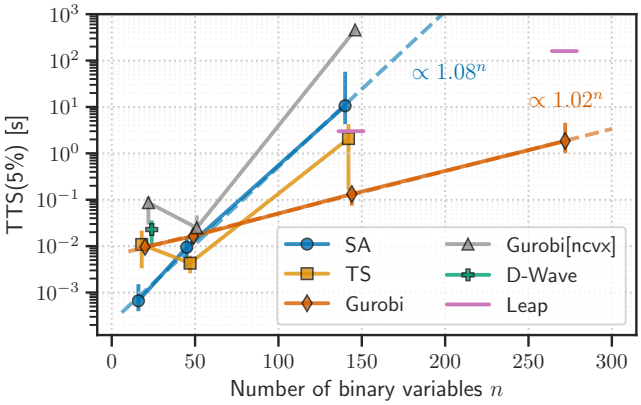

Die Plots zeigen klar, dass Gurobi mit konvexer Problemformulierung alle anderen Solver hinsichtlich der Lösungsqualität übertrifft und das günstigste Skalierungsverhalten aufzeigt. Quantum Annealing schneidet dagegen schlecht ab, bereits bei case14 lag der relative Fehler bei über 20% und bei case24 bei fast 1000%. TTS kann nur für die kleinste Problemgröße berechnet werden, weil keine ausreichenden Lösungen gefunden wurden. Leap zeigt Lösungsqualität vergleichbar mit klassischen Heuristiken. Nur SA zeigt ausgeprägtes exponentielles Skalierungsverhalten der TTS, jedoch mit einer höheren Basis als Gurobi. Bei den anderen Algorithmen ist es wegen zu wenig Datenpunkten schwierig einen Fit zu erstellen.

Fazit

Das hier entwickelte binäre Optimierungsmodell erwies sich als geeignet für den Anwendungsfall der Zuordnung von P2P-Netzbetriebskosten. Hinsichtlich der Anwendbarkeit von Quantenoptimierungstechniken zeigte die Untersuchung, dass bei einer konvexen Formulierung des kleinste Quadrate Problems, der klassische Solver jede Heuristik übertraf, wobei Quantum Annealing besonders schlecht abschnitt. Dies stellt die sinnvolle Anwendung von QA zur Lösung des Leistungsflussanpassungsproblems erheblich in Frage, da klassische Methoden bessere Lösungen schneller finden und ein günstigeres Skalierungsverhalten aufweisen. Selbst der hybride Leap Algorithmus schneidet hier im Vergleich zu UC1 und UC2 deutlich schlechter ab.
Die Ergebnisse deuten darauf hin, dass binäre kleinste Quadrate Probleme für Quantenmethoden und

klassische Heuristiken inhärent schwierig sein können. Ob diese Schlussfolgerung auf allgemeine konvexe Optimierungsprobleme übertragbar ist, bleibt eine offene Frage, die weiterer Untersuchung bedarf.

AP4: Benchmarking System

Die Methoden der Benchmarks wurden bereits in AP3 für die einzelnen Anwendungsfälle erläutert. Die Hauptmethode für die Benchmarks, die in allen drei Anwendungsfällen zum Einsatz kam, war das Vordefinieren einer Laufzeit (meistens problemgrößenabhängig) für alle Lösungsalgorithmen und das nachfolgende Vergleichen der Lösungsqualität, anhand der besten gefundenen Lösung pro Algorithmus. Da besonders der hybride Service von D-Wave, Leap, nur über das Einstellung eines Laufzeitparameters verfügt, waren wir auf diese Art von Benchmarking angewiesen, um faire Ergebnisse zu erhalten.
Für die Experimente wurde eine Software-Infrastruktur gebaut, die alle Ergebnisse eines Algorithmus in eine Datenbank gespeichert hat. Sollte ein Algorithmus bereits einen Problemfall gelöst haben, kann die gespeicherte Lösung direkt verwendet werden. Sollten sich jedoch die Hyperparameter geändert haben, wird eine neue Ausführung gestartet. Dadurch waren wir in der Lage schnell und zuverlässig viele verschiedene Experimente laufen zu lassen, z.B. zur Optimierung der Hyperparameter einiger Lösungsalgorithmen.

AP5: Generalisierung der Algorithmen

Neben der von der LMU entwickelten allgemeinen Algorithmen zum Lernen von QUBO-Formulierungen, spezialisierten wir uns in einem Teilprojekt auf ein praktisches Problem in der Quantenoptimierung: Nebenbedingungen müssen durch Strafterme ausgedrückt werden. Im Falle von Ungleichheits-Nebenbedingungen müssen zusätzlich noch Schlupf-Variablen zum Optimierungsproblem hinzugefügt werden. Beide Methoden führen dazu, dass das Problem deutlich schwieriger zu lösen wird. Für den Quantum Approximate Optimization Ansatz (QAOA), einem sehr vielversprechenden Algorithmus zur Lösung kombinatorischer Optimierungsproblem auf universellen Quantencomputern, wurden jüngst einige Schaltkreismodifikationen vorgestellt, die Nebenbedingungen in die Architektur integrieren und somit die Effizienz des Algorithmus deutlich erhöhen. Am Beispiel eines Lastenplanungsproblems kombinierten wir zwei Nebenbedingungs-Methoden zur Lösung.
Paper: "Efficient QAOA Architecture for Solving Multi-Constrained Optimization Problems," 2025, accepted at IEEE QCE 2025

Problemformulierung

Das Lastenplanungsproblem (oder auch Prosumer-Problem) ist eine Modifikation des bekannten Multi-Knapsack Problems. Ziel ist es über einen diskreten Zeithorizont hinweg die Startzeiten bestimmter Lasten so zu wählen, dass der gesamte Strompreis minimiert wird und eine maximale Last pro Zeitpunkt nicht überschritten wird (Knapsack Nebenbedingung). Der Startzeitpunkt kann durch eine binäre Variable pro Zeitschritt ausgedrückt werden, wobei nur genau eine Variable pro Last auf Eins gesetzt werden kann (One-Hot Nebenbedingung).

$$\min_{x} \sum_{t} \sum_{i} x_{i,t} \sum_{t'} l_{it'} r_{t+t'} \quad \text{so dass} \quad \sum_{t} x_{i,t} = 1 \ \forall i \quad \text{und} \quad \sum_{i} \sum_{t'} x_{i,t-t'} l_{d_i - t'} \leq W_t$$

Das Problem hier ist spezialisiert auf einen Energieanwendungsfall, jedoch kommen Problem mit Nebenbedingungen ähnlicher Art sehr häufig in industriellen Anwendungen zum Vorschein.

Modifizierter QAOA-Algorithmus

Der QAOA-Algorithmus basiert auf der abwechselnden Applikation eines Kostenoperators und eines Mixer-Operators. Der Kostenoperator addiert eine Phase in Abhängigkeit der Kostenfunktion auf den Quantenzustand. Der Mixer-Operator interferiert und verändert damit die Amplitude der Basiszustände. XY-Mixer sind eine aus der Literatur bekannte Methode, um One-Hot Nebenbedingungen in QAOA zu integrieren. Im Gegensatz zu dem normalen X-Mixer, führen XY-Mixer nur zu Wahrscheinlichkeitstransfer zwischen erlaubten Zuständen. Das heißt, beginnt der Algorithmus in einer Superposition aus erlaubten Zuständen, den sogenannten W-Zuständen, wird eine Kombination aus Kostenoperator und XY-Mixer am

Ende nur erlaubte Lösungen messen. Die XY-Mixer sind durch die Abwandlung von XY-Ring-Mixern einfach auf Quantenhardware zu implementieren, da sie Im Wesentlichen aus zwei 2-Qubit Pauli Rotationen bestehen.
Obwohl es in Literatur Konstruktionsalgorithmen für Ungleichheits-Nebenbedingung-Mixer gibt, sind diese deutlich komplexer zu implementieren. Deshalb wählten wir einen anderen Ansatz für diese Nebenbedingungen, der auch letztens in Literatur untersucht wurde: IF-QAOA. Hierfür wird ein Orakel verwendet, welches berechnet, ob die Nebenbedingung erfüllt ist oder nicht. Sollte dies nicht der Fall sein wird eine konstante Strafe auf die Phase addiert, d.h.

$$\min_{x} f(x) \;\; \text{s.d.} \;\; g(x) \geq 0 \qquad \rightarrow \qquad \min_{x} f(x) + \rho\,(1 - \Theta[g(x)]),$$

wobei Θ die Heaviside-Theta Stufenfunktion ist. Das heißt IF-QAOA benötigt zwar wiederum einen Strafterm und zusätzliche Qubits, allerdings sind diese Qubits nicht Teil des Suchraums und der Strafterm bleibt konstant im Vergleich zur quadratisch ansteigenden Strafe der QUBO-Methode. Die konstante Strafe sorgt dafür, dass das Energiespektrum einen kleineren Bereich einnimmt, was generell von Vorteil für Quantenoptimierung ist. Der nachfolgende Schaltkreis zeigt einen Überblick über die kombinierte QAOA-Architektur.

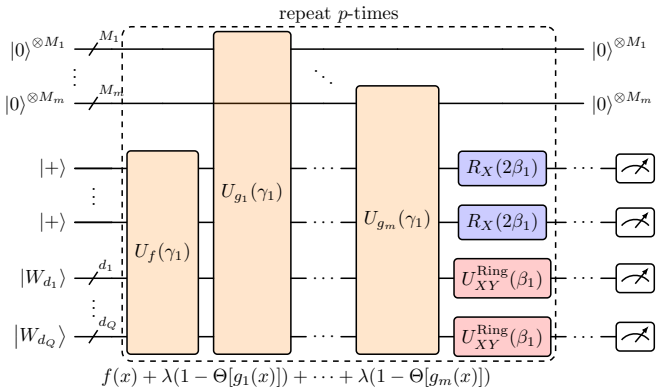

Simulator Evaluation

Durch intelligentes Ausnutzen der Struktur des obigen Schaltkreises hat die Aqarios einen Simulator entwickelt, der nur einen Bruchteil der Zustandsvektor-Größe für die Simulation benötigt und damit Problemgrößten simulieren kann die durch normale Zustandsvektor-Simulation nicht möglich sind.
Wir haben die kombinierte QAOA-Architektur gegen die QUBO-Methode mit quadratischen Strafen und zusätzlichen Qubits verglichen. Zudem haben wir noch die zwei Zwischenmethoden (nur XY und nur IF) mit verglichen. Als Instanzen haben wir 24 zufällige Testfälle erzeugt, die jeweils vier unterschiedliche variable Stromtarife besitzen (steigend, fallend, quadratisch nach oben, quadratisch nach unten). Die Optimierung der variationellen Parameter des QAOA erfolgte mit dem BFGS-Algorithmus (max. 100 Iterationen) und wir haben eine Interpolationsmethode benutzt: Gestartet wurde bei einer QAOA-Iteration und die zwei Parameter wurden optimiert, dann wurde interpoliert auf $p = 2$ mit vier Parametern, so lange bis $p = 12$ erreicht wurde.
Für die Ergebnisse wurden zwei Metriken herangezogen: Die Lösungsqualität als Random-Adjusted Approximation Ratio (RAAR),
bedeutet bei $\text{RAAR} = 1$ wird immer die optimale Lösung gemessen, bei $\text{RAAR} = 0$ sind die Ergebnisse zufällig. Die zweite Metrik ist die Wahrscheinlichkeit eine optimale Lösung zu messen P^*.
Die kombinierte Methode zeigt eindeutig, dass sie den anderen Methoden überlegen ist, sowohl

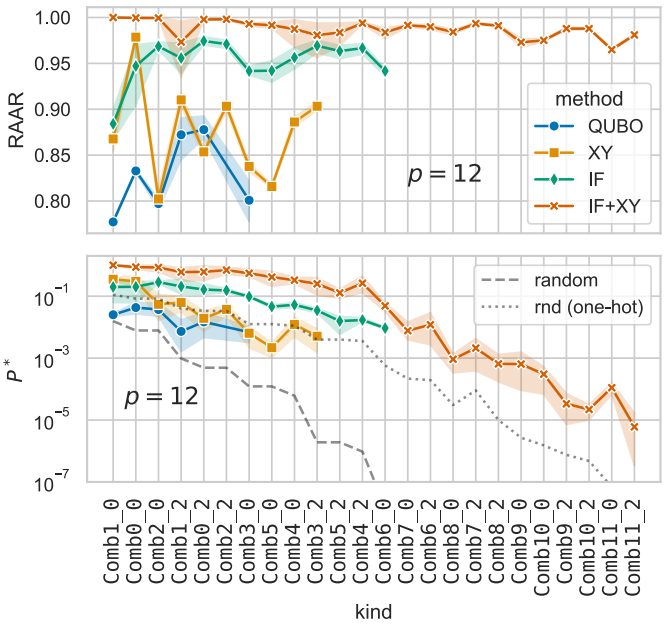

RAAR als auch P^* sind bei IF+XY deutlich über den verglichenen QAOA-Algorithmen. Auch die extrapolierte TTS, basierend auf P^* und der Schaltkreis-Tiefe (hier nicht gezeigt), ist schneller für IF+XY. Das zeigt, dass die leicht komplexere Schaltkreisarchitektur insgesamt einen deutlichen Vorteil für die Optimierungsgeschwindigkeit liefert.

Hardware-Experimente

Nach den erfolgreichen Experimenten auf den Simulatoren, haben wir zusätzlich Experimente auf IBM Hardware mit dem erweiterten Algorithmus gemacht. Wir haben mit einem Test der W-Zustände begonnen, welcher schon deutlich gezeigt hat, dass wir wenig zulässige Ergebnisse messen werden, weil der das Rauschen und der Auslesefehler zu groß ist. Aus diesem Grund haben wir eine zusätzliche Nachbearbeitungsmethode implementiert, die falsch gemessene Zuweisungen korrigiert, indem sie die entsprechenden Bits negiert. Eine Lösung, welche die One-Hot-Bedingung nicht verletzt, wird durch die Nachbearbeitung nicht weiter verändert.

Da die XY-Mixer deutlich weniger Ressourcen benötigt wie das Orakel der IF-QAOA, haben wir uns in die XY-Mixer im speziellen angeschaut. Dafür haben wir ein Optimierungsproblem geschaffen, dass der Hardware-Topologie entspricht, damit mit kurzen Schaltkreisen implementierbar ist. Dieses Spin-Glas ähnliche Problem, ist in der folgenden Abbildung auf der linken Seite dargestellt. Die Farben enkodieren dabei Qubits die einer One-Hot-Bedingung unterliegen und die Roten kanten stellen zufällig gewählte Interaktionen zwischen den Qubits dar.

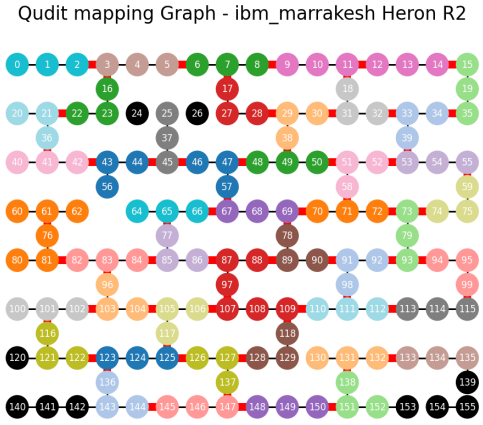

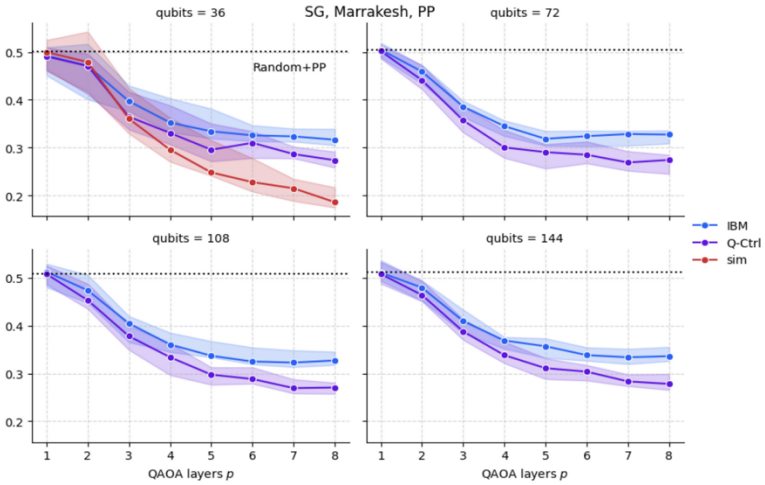

Das führt zu QAOA-Schaltkreisen, die sehr kurz sind (ca. 8-10 Schichten pro QAOA-Iteration), was wiederum bedeutet, dass durchaus Ergebnisse erwartbar sind. Die Ergebnisse auf IBM-Marrakesch sind auf der rechten Seite zu sehen und zeigen den relativen Energie-Fehler nach der Nachbearbeitung von IBM mit Standard Fehler-Mitigation und der Fehler-Mitigation von Q-Ctrl. Zusätzlich ist für den kleinsten Fall mit 36 Qubits Simulation noch möglich. Die Parameter wurden im Vorhinein auf einen linearen Anstieg/Abfall eingestellt. Es ist klar ersichtlich, dass mit zunehmender QAOA-Tiefe die Ergebnisse besser werden, jedoch nicht so gut wie bei dem Simulator, was höchstwahrscheinlich dem Rauschen geschuldet ist. Die Fehler-Mitigation von Q-Ctrl führt zudem zu besseren Ergebnissen als die von IBM. Als Referenz ist zusätzlich die gepunktete Linie eingezeichnet, die der Nachbearbeitung von zufälligen Lösungen entspricht. Das bedeutet QAOA mit XY-Mixer funktioniert hier auf echter Hardware.

Die Lastenplanungsprobleme führen allerdings schon bei einer QAOA-Iteration zu sehr tiefen Schaltkreisen (>100), wodurch die Ergebnisse, selbst für die kleinsten Instanzen, schlecht wurden. Die Nachbearbeitung konnte die Ergebnisse zwar verbessern, allerdings hatten sie dieselbe Güte wie die Nachbearbeitung von zufälligen Lösungen. Das heißt für praktisch relevante Probleme muss die Hardware noch besser werden.

Fazit

Insgesamt lässt sich zusammenfassen, dass die kombinierte Methode von QAOA Schaltkreismodifikation in der Theorie und der numerischen Simulation zu deutlich besseren Ergebnissen führt und somit

praktisch relevante Probleme mit Nebenbedingungen lösen kann. Allerdings ist der Schaltkreis für relevante Probleme, wie das Lastenplanungsproblem, noch zu groß, um auf aktueller Hardware erfolgreiche Optimierung zu erreichen. Für ein konstruiertes Beispiel mit XY-Mixern haben wir gezeigt, dass die aktuelle Hardware bereits heute gute Ergebnisse liefern kann.

AP6: Evaluation und Skalierung auf Echtwelt-Problemgrößen

Die Evaluation der Lösungsgüte unserer Algorithmen wurde bereits in den Anwendungsfällen in AP3 diskutiert. Kurz lässt sich zusammenfassen, dass die Zerteilungsmethode, entwickelt für UC1, sehr skalierbar ist und Echtwelt-Problemgrößen (>1000 Kunden) noch effektiv gelöst hat. Zwar sind aktuelle Quantencomputer noch zu klein, um die Teilprobleme effizient zu lösen, jedoch haben die Experimente mit klassischen und hybriden Lösungsalgorithmen gezeigt, dass die reinen Quantenroutinen modular eingebaut werden können und gute Lösungsqualität zu erwarten sind, sobald diese verfügbar sind. Eine Idee, Anwendung auf noch größeren Instanzen zu ermöglichen, wäre Clustering der Kunden zu betreiben, um die Anzahl der effektiven Einzelkunden zu verringern.
In UC2 hat unsere hybride Methode ebenfalls sehr gute Skalierung angedeutet. So wurden auf Instanzen mit 300 Knoten die besten Ergebnisse mit der hybriden Aufspaltungs-Methode erreicht. Zudem wurde das erste Teilproblem mit bis zu 1888 Knoten gelöst. Da die D-Wave's hybrider Solver und SA, die klassische Heuristik, die Quanten-Annealing am verwandtesten ist, sehr gute Ergebnisse geliefert haben, ist davon auszugehen, dass reine Quantenmethoden in der Zukunft auch gute Ergebnisse liefern werden. Aktuelle Hardware ist jedoch leider limitiert in der Anzahl der Qubits und Verbindungen, kann daher noch keine verlässlichen Resultate erzeugen.
In UC3 gab es kein positives Skalierungsergebnis. Die Evaluation auf Probleminstanzen bis 50 Kunden hat ergeben, dass rein klassische Methoden die Struktur des Problems am besten ausnutzen können und deshalb auch am besten skalieren. Eine zukünftige, sinnvolle Quantenanwendung ist in UC3 nicht ersichtlich, im Vergleich zu den positiven Ergebnissen von UC1 und UC2.

AP7: Ausdehnung auf andere Sektoren

Die in *"Reducing QUBO Density by Factoring Out Semi-Symmetries"* des LMU-Teilprojekts, entwickelte Methode bietet einen breit anwendbaren Ansatz für die Optimierung von Quadratic Unconstrained Binary Optimization (QUBO) Problemen, dem mathematischem Modell, das von vielen Quanten- und klassischer Optimierungsalgorithmen verwendet wird. Durch die Identifizierung und Ersetzung von Semi-Symmetrien wird die Dichte in den QUBO-Matrizen erheblich reduziert, was zu einer geringeren Tiefe der Schaltkreise in Quantenalgorithmen wie QAOA und einer Vereinfachung der Einbettung in Quanten-Annealer führt. Diese Verbesserung kommt der gesamten Forschungsgemeinschaft zugute, die sich mit kombinatorischer Optimierung befasst, da sie die Skalierbarkeit und Effizienz bei der Lösung praktischer, umfangreicher Probleme sowohl auf Quanten- als auch auf klassischer Hardware erhöht. Die Methode ist auf eine Reihe von kombinatorischen Optimierungsproblemen anwendbar, darunter Maximum Clique, Hamiltonkreis, Graphenfärbung und Graphen-Isomorphismus, die alle von Natur aus Semi-Symmetrien aufweisen.
Das Paper *"Towards Less Greedy Quantum Coalition Structure Generation in Induced Subgraph Games"*, des LMU-Teilprojekts, stellt Methoden zur verbesserten Erzeugung von Koalitionsstrukturen mithilfe von kombinatorischer Optimierung vor, indem die Abhängigkeit von greedy Heuristiken verringert wird. Diese Methoden erforschen effizient einen breiteren Lösungsraum und ermöglichen die Entdeckung von Lösungen mit höherer Qualität im Vergleich zu traditionellen gierigen Ansätzen. Der vorgeschlagene Algorihtmus ist allgemein auf alle Optimierungsprobleme anwendbar, die Koalitionsstrukturspiele oder graphenbasierte Formulierungen beinhalten, was ihn für verschiedene Bereiche wie Wirtschaft, Ressourcenallokation und Analyse sozialer Netzwerke wertvoll macht, in denen eine optimale Koalitionsbildung entscheidend ist.
Die in *"Black Box Optimization Using QUBO and the Cross Entropy Method"* des LMU-Teilprojektsentwickelte Methode ist auf verschiedene Optimierungsprobleme außerhalb des Energiesektors anwendbar. Durch den Einsatz des BOX-QUBO-Ansatzes, der die Quadratic Unconstrained Binary Optimization (QUBO) mit der

Cross-Entropy-Methode kombiniert, können diese Techniken komplexe Optimierungsprobleme in Bereichen wie Logistik, Finanzen und maschinelles Lernen effektiv angehen. Die Anpassungsfähigkeit des BOX-QUBO-Ansatzes ermöglicht es, Probleme zu modellieren und zu lösen, bei denen nur die Zielfunktion bekannt ist, eine direkte Formulierung dagegen schwer zu finden ist, was sie zu einem wertvollen Werkzeug für eine breite Palette von Anwendungen macht.
Die *"Evaluating Quantum Optimization for Dynamic Self-Reliant Community Detection"* verwendet eine gierige Heuristik zur Erkennung von Energie-Gemeinschaften vor, die das Konzept der Selbstständigkeit innerhalb der Gemeinschaften einbezieht. Das Kriterium der Eigenständigkeit ist zwar auf Energienetzwerke zugeschnitten, stellt aber eine allgemeine Einschränkung des Ressourcenausgleichs dar. Es könnte an andere Bereiche angepasst werden, z. B. an soziale Netzwerke (Schaffung von Gemeinschaften mit intern ausreichenden Ressourcen oder Attributen).
Die in *"Incentivising Demand Side Response through Discount Scheduling using Hybrid Quantum Optimization"* vorgestellte Dekompositionsmethode verbindet klassische Dekompositionsalgorithmen mit Quanten-Subroutinen, um große Problemgrößen von einigen tausend Verbrauchern zu erreichen. Diese Technik ist potenziell auf andere große kombinatorische Optimierungsprobleme anwendbar, insbesondere auf solche mit einer Zeitplanungsstruktur. Insbesondere kann sie auf Probleme ausgedehnt werden, die globale Beschränkungen für jeden Zeitschritt und lokale Beschränkungen für einzelne Elemente beinhalten, was einen ähnlichen Zerlegungsansatz ermöglicht.
In dem Paper *"Efficient QAOA Architecture for Solving Multi-Constrained Optimization Problems"* wurden Indikatorfunktionen, um Ungleichheitsbeschränkungen in QAOA zu integrieren mit XY-Mischern zur Durchsetzung von One-Hot-Beschränkungen kombiniert. Indikatorfuntionen applizieren konstante Strafwerte nur auf Zustände, die die Beschränkungen verletzen. Als Konsequenz wird der Suchraum im Gegensatz zu QUBO-Methoden verringert und die Performance des QAOA-Algorithmus erhöht. Die Realisierbarkeit dieses Ansatzes wird auf die Minimierung der Energiekosten für Prosumer in einem Netz demonstriert, kann aber auf jedes binäre Optimierungsproblem mit Ungleichheits- und One-Hot-Beschränkungen erweitert werden.
In *"A Competitive Showcase of Quantum versus Classical Algorithms in Energy Coalition Formation"* wird eine Methode zur Umwandlung des Coalition Formation Game (CFG) in ein Induced Subgraph Game (ISG) vorgestellt. Diese Transformation ermöglicht eine effizientere Modellierung von Koalitionsbildungsproblemen und macht die Methode für eine breite Palette von Optimierungsaufgaben anwendbar, bei denen es um die Bildung von Koalitionsstrukturen geht, nicht nur für Energiedomänen.

AP8: Plan zur Industrialisierung des Systems

Die bisherige Forschung in Q-Grid fokussierte sich auf Anwendungsfälle und Methoden, bei denen Quantenalgorithmen klassische Verfahren in Bezug auf Laufzeit oder Lösungsqualität übertreffen könnten. Ebenso wichtig ist jedoch sich Gedanken zu machen, wie diese Quantenanwendungen in realen Produktionsumgebungen betrieben werden können. Dies erfordert die Automatisierung der Ausführung von Quantensoftware.
In diesem Zusammenhang hat sich **Quantum Software Engineering (QSE)** etabliert, die klassische Prinzipien der Softwaretechnik auf die Entwicklung von Quantensoftware anwendet und gleichzeitig die besonderen Herausforderungen adressiert, die sich aus dem Einsatz von Quantenhardware ergeben.
Der Betrieb von Quantensoftware in modernen Cloud-Umgebungen ist heute eine etablierte Praxis. Große Cloud-Anbieter wie AWS, Microsoft, Google und IBM bieten über die Cloud Zugang zu Quantenhardware, was eine nahtlose Integration in Unternehmens-Workflows und DevOps-Pipelines ermöglicht. Diese Zugänglichkeit ist insbesondere angesichts der Einschränkungen aktueller NISQ-Hardware (Noisy Intermediate-Scale Quantum) von großer Bedeutung. Dennoch bleibt der Aufbau produktionsreifer Quantenanwendungen komplex: Die Integration von Quanten-Backends in traditionelle Cloud-Architekturen stellt erhebliche softwaretechnische und architektonische Anforderungen.
Um Quantenanwendungen erfolgreich in Produktionsumgebungen zu integrieren, ist es unerlässlich, skalierbare und wartbare Software-Engineering-Praktiken zu übernehmen. In unserer Publikation *„Quantum Software Architecture Blueprints for the Cloud: Overview and Application to Peer-to-Peer Energy Trading"* haben wir eine hybride Quantum-Cloud-Architektur vorgestellt. Diese nutzt bewährte Komponenten der klassischen

Softwaretechnik – darunter Continuous Integration and Deployment (CI/CD), Infrastructure as Code, Containerisierung und mehrstufige Deployment-Pipelines – um Zuverlässigkeit und Flexibilität sicherzustellen. Sie ermöglicht es, Quantenanwendungen mit der gleichen Qualität zu entwickeln, zu testen und bereitzustellen wie klassische Systeme. Am Beispiel eines Peer-to-Peer-Energiehandels (ähnlich zu UC3 in AP3) demonstrieren wir, wie Quantensoftware industriell einsetzbar gemacht werden kann. Zentrale Bausteine dieser Architektur umfassen:

- **Bereitstellungsumgebungen:** Wir schlagen ein cloud-agnostisches Bereitstellungsmodell vor, das auf etablierten DevOps-Prinzipien basiert und drei gestaffelte Umgebungen umfasst: Entwicklung (DEV), Qualitätssicherung (QA) und Produktion (PROD). Jede Umgebung nutzt die gleichen containerisierten Komponenten, was sicheres Testen und Konfigurationsvalidierung vor der Freigabe ermöglicht. Dies gewährleistet hohe Zuverlässigkeit und minimiert Ausfallzeiten. Die nachstehende Abbildung zeigt das Zusammenspiel dieser Umgebungen mit Quanten-Cloud-Diensten.
- **Kernkomponenten:** Die Quantenanwendung wird containerisiert (z. B. mit Docker) und in einem Cloud-basierten Container-Registry gespeichert. Ein Scheduler startet Container je nach Bedarf, während ein Deployment-Service den aktuellen Container auf klassischen Server ausführt. Die Ausgabe der Quantenalgorithmen wird sowohl in Dateisystemen als auch in relationalen Datenbanken gespeichert – zur Überwachung, Nachverarbeitung und Visualisierung. Eingangsdaten – etwa Energieverbrauch oder Wettervorhersagen – werden über Dateien eingebunden, um die Integration in unterschiedliche organisatorische Infrastrukturen und regulatorische Anforderungen zu unterstützen.
- **Build-Pipeline:** Eine CI/CD-Pipeline sorgt für robustes Code-Management und automatisierte Bereitstellung. Änderungen am Code werden per Git eingecheckt, woraufhin automatisierte Tests und Container-Builds ausgelöst werden. Nach erfolgreicher Validierung werden die Container-Images versioniert und sicher gespeichert. Zugangsdaten für Cloud-Speicher, Datenbanken und Quantenhardware werden über sichere Key-Vault-Dienste verwaltet. Container werden zunächst in der DEV-Umgebung bereitgestellt und nach erfolgreichem Testen in die QA- und schließlich PROD-Umgebung überführt.

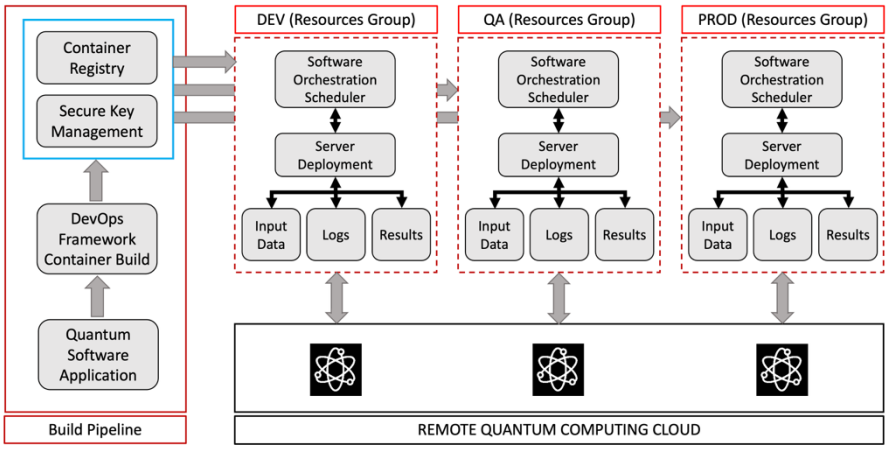

Das Setup für Continuous Integration und Deployment von Quantensoftware

Zusammenfassung und Ausblick

Das Q-GRID-Projekt hat erfolgreich demonstriert, dass Quantencomputing-Techniken vielversprechende Ansätze für die Optimierung zukünftiger dezentraler Energienetze bieten können. Über die dreijährige Projektlaufzeit hinweg wurde ein umfassendes Forschungsprogramm realisiert, das sowohl theoretische Grundlagen als auch praktische Anwendungen adressierte.

Methodische Innovationen

Im Bereich der algorithmischen Entwicklung erzielte das Projekt mehrere bedeutende Durchbrüche. Das LMU-Teilprojekt entwickelte mit dem Semi-Symmetrie-Ansatz eine neuartige Vorverarbeitungsmethode für QUBO-Probleme, die eine signifikante Reduktion der Kopplungsdichte ermöglicht und damit sowohl die Einbettung auf

Quantum-Annealing-Hardware als auch die Schaltkreistiefe bei QAOA deutlich verbessert. Ergänzend wurde mit BOX-QUBO ein universeller Black-Box-Optimierungsworkflow etabliert, der die automatisierte Anwendung von Quantenoptimierung ohne aufwändige Neumodellierung ermöglicht. Darauf aufbauend wurde dieser automatische Optimierungsworkflow mit DeepSAT erweitert, einer Methode, die mit Neuronalen Netzen über den Umweg von SAT-Formeln QUBO-Formulierungen erlernt.

Das E.ON/Aqarios-Teilprojekt trug mit problemspezifischen Zerlegungsalgorithmen bei, die große Optimierungsprobleme in kleinere, quantenhardware-taugliche Teilprobleme zerlegen, ohne harte Nebenbedingungen als Strafterme formulieren zu müssen. Ein systematisches Benchmarking-System ermöglichte faire Vergleiche zwischen klassischen und quantenunterstützten Lösungsansätzen durch einheitliche Zeitlimits und standardisierte Metriken. Des Weiteren wurde der QAOA-Algorithmus mit Kombination von XY-Mixern und Indikatorfunktionen für harte Nebenbedingungen erweitert. Simulationen dieser QAOA-Erweiterung zeigte deutliche Verbesserungen gegenüber konventionellen QUBO-Formulierungen.

Anwendungen im Energienetz

Die drei untersuchten Anwendungsfälle des zukünftigen Energienetzes zeigten unterschiedliche Grade der Quanteneignung. Das Discount Scheduling Problem für dynamische Preisgestaltung erwies sich als besonders vielversprechend: Die entwickelte Zerlegungsmethode ermöglichte die Skalierung auf über 3200 Kunden, wobei quantenunterstützte Hybrid-Solver ab 200 Kunden klassische Solver übertrafen. Der D-Wave LeapHybridCQM-Solver lieferte dabei nicht nur bessere Lösungsqualität, sondern auch fairere Rabattverteilung zwischen den Kunden.

Für die Identifikation autarker Energiegemeinschaften wurden zwei Formulierungen untersucht. Auf der einen Seite wurde das Self-Reliant Community Detection Problem entwickelt, bei dem ein hybrider Zerteilungs-Algorithmus auf Netzen mit bis zu 1888 Knoten überzeugende Ergebnisse zeigte. Auf der anderen Seite wurde eine Formulierung basierend auf kooperativer Spieltheorie, ebenfalls mit einer Zerteilungsmethode, untersucht, wobei Quantenanneling mit D-Wave besseres Skalierungsverhalten als klassische Lösungsmethoden aufzeigte. Verschiedene Zerteilungsmethoden wurden von der LMU für dieses Problem genauer untersucht, mit dem Ergebnis, dass eine iterative 4-fach Zerteilung die Besten Ergebnisse liefern kann, jedoch das Rauschen aktueller Quantenhardware die Anwendung auf 2-fach Zerlegung beschränkt.

Die Untersuchung von Peer-to-Peer Energiemärkten offenbarte hingegen wichtige Grenzen: Hier zeigten klassische Solver mit konvexer Problemformulierung deutlich bessere Skalierungs-eigenschaften als alle getesteten Quantenmethoden.

Gesammelte Erkenntnisse und Ausblick

Die wichtigsten Erkenntnisse betreffen sowohl technische als auch strategische Aspekte. Problemspezifische Hybridansätze und intelligente Zerlegungsmethoden erwiesen sich oft als entscheidender für den praktischen Erfolg als die reine Quantenhardware-Leistung. Die Struktur der Optimierungsprobleme ist kritisch: Kombinatorische Probleme mit exponentieller klassischer Komplexität sind generell gute Kandidaten für Quantenvorteile, wobei hingegen konvexe Probleme keine Vorteile zeigten. Aktuelle NISQ-Hardware reicht noch nicht für produktive Anwendungen, aber hybride Cloud-Services wie D-Wave's Leap bieten bereits heute praktische Vorteile. Allerdings muss bei den hybriden Cloud-Services auch beachtet werden, dass keine Transparenz besteht, wie viel der tatsächlichen Optimierungsleistung auf Quantenhardware zurückzuführen ist. Zukünftige Fortschritte in der Hardwareentwicklung werden es ermöglichen, dass die vorgestellten Algorithmen und Methoden in noch größerem Umfang und mit noch besserer Effizienz zum Einsatz kommen können.

Für zukünftige Forschung ergeben sich vielversprechende Richtungen: Die entwickelten Zerlegungsmethoden sollten auf weitere Energieoptimierungsprobleme ausgeweitet werden, beispielsweise Vehicle-to-Grid-Integration und Energiespeicher-Optimierung. Die Vorverarbeitungsmethoden bieten großes Potenzial für andere industrielle Optimierungsprobleme außerhalb des Energiesektors. Die Kombination mit fortschrittlichen Machine Learning Techniken könnte zu vollständig automatisierten Quantenoptimierungs-Pipelines führen. QAOA kann über die untersuchten Erweiterungen hinaus für andere Nebenbedingungen modifiziert werden und hardwareeffiziente Schaltkreisimplementierungen gefunden werden.

Langfristig zeigt das Q-GRID-Projekt, dass Quantencomputing das Potenzial hat, zu einer Schlüsseltechnologie für die Energiewende zu werden. Die Komplexität dezentraler, erneuerbarer Energiesysteme stellt klassische

Optimierungsmethoden vor erhebliche Herausforderungen, während die entwickelten Quantenansätze bereits heute erste praktische Vorteile bieten und mit der weiteren Hardwareentwicklung zu unverzichtbaren Werkzeugen werden könnten. Die innovativen Ansätze des Projekts schaffen somit nicht nur den theoretischen Rahmen für die Lösung von NP-schweren Problemen, sondern liefern auch konkrete, anwendungsnahe Instrumente, um komplexe Energienetzstrukturen zu optimieren und nachhaltig zu gestalten. Das Projekt hat somit sowohl wichtige wissenschaftliche Erkenntnisse generiert als auch den Grundstein für die praktische Nutzung von Quantencomputing in der Energiewirtschaft gelegt.