

研究目的


Keywords: Batteries, Thermal energy storage, Heat source machine, Optimal control, Artificial intelligence, Annual optimisation, District heating and cooling, Heat-sharing network

1 普及に課題のある「システム運用最適化」

- 1) 蓄電池の充放電はいつ？どの程度？
- 2) 蓄熱槽の蓄熱・放熱はいつ？どの程度？
- 3) 熱源機の運転はいつ？どの熱源機を？どの程度？

簡単なシステム構成ならある程度合理的に運転できるが…

2 複雑なシステム・街区モデルには適用が難しい



3 解決すべき課題は？

- 1) 複雑な計算にも対応出来る最適化手法の確立
- 2) 実際のエネルギーシステムとの協和(今後の課題)

4 最適化手法の向上を目指す

■最適化手法に必要とされる性能は？

- 1) 高速に計算できる→リアルタイム制御へ応用
- 2) 解の精度を維持する→複雑なシステムでは常に
真の最適解が求まるとは限らない
- 3) 高い汎用性
 - i. あらゆる関数形状に対応する→機器のモデル化に制限なし
 - ii. 非定常計算に対応する
→水温変化などは反復計算で非定常現象を
モデル化する必要がある

5 人工知能: メタヒューリスティクスの利用

メタヒューリスティクスとは人工知能の一種で、あらゆる関数形状を直接解くことができる発見・学習的手法の総称: 今回は ϵ DE(**epsilon constrained differential evolution**)という手法を利用

最適化手法: メタヒューリスティクス (生物の進化・行動を模倣)

Keywords: Batteries, Thermal energy storage, Heat source machine, Optimal control, Artificial intelligence, Annual optimisation, District heating and cooling, Heat-sharing network

利用した最適化手法: ϵ DE-RJ (Epsilon differential evolution with random jumping)

役割: 探索

差分進化 (DE: differential evolution)

役割: 制約処理

ϵ 制約法 (Epsilon constrained method)


役割: 局所解脱出

ランダムジャンピング (RJ: random jumping)


【DEのアルゴリズム + RJ】

1. 初期化: 一様乱数を用いてランダムに個体 ($N_{pop} = 100$) を作成
2. 評価: 各個体の評価
3. 新個体の作成
 - 1) 個体 x_i ($i = 1$) から順に $i = N_{pop}$ までループ開始
 - 2) 個体 x_i と被らないように集団から二つの個体 (x_m, x_n ($m \neq n \neq i$)) を選択
 - 3) ドナー個体を作成: $\vec{v}_i^{g+1} = \vec{x}_i^g + M(\vec{x}_m^g - \vec{x}_n^g)$, M : 突然変異率 ($=0.5$)
 - 4) 交叉: ランダムジャンピング適用

Rand	0.23	0.87	交叉率=0.7
$\vec{x}_i^g$	0.78	0.23	→ 同じ数値の場合 一様乱数に置換
$\vec{v}_i^{g+1}$	0.82	0.56	
$\vec{x}_i^{g+1}$	0.82	0.23	




【定式化: 変数の設定】



【 ϵ 制約法のアルゴリズム】

- 1) 個体群 (x_i^g) の初期化
- 2) ϵ 値 ($=1$) の初期化 (これ以降指数関数的に減少)
- 3) 新個体 (x_i^{g+1}) の生成
- 4) 制約逸脱度 (ϕ) と目的関数値 (f) の計算
- 5) $\phi < \epsilon$ の時, f_i^g と f_i^{g+1} を比較
 $\phi \geq \epsilon$ の時, ϕ_i^g と ϕ_i^{g+1} を比較
- 6) 良い方を入れ替えて3)に戻る



コージェネレーションを含む複数蓄エネ設備の最適化

Keywords: Batteries, Thermal energy storage, Heat source machine, Optimal control, Artificial intelligence, Annual optimisation, District heating and cooling, Heat-sharing network


単目的最適化（1日の電気料金とガス料金を最小化する）

1 εDEの利用で高速計算が可能に


- ❖ 14種類336変数を市販の一般的なPCにおいて、**6分**で最適化
- ❖ εDEの計算量は変数の数に依存しない
⇒ **従来より高速に非線形最適化が可能**となった。
- ❖ 冷却水温変化は反復計算にて非定常計算をモデル化する
- ❖ 機器のモデルは曲線関数を最適化する必要がある

2 最適な運転スケジュールを実現

- ❖ CGSは買電価格の高い時間帯のみ稼働
- ❖ 同種機器の同時稼働では同負荷率が理論的に最適である。
- ❖ 最適化結果ではAHP1, 2共に概ね同負荷率での運転となっており、**最適解が妥当であることを確認。**



エネルギーシステム






ニューラルネットワークと ε DE-RJによる地域エネルギーシステム最適化

Keywords: Batteries, Thermal energy storage, Heat source machine, Optimal control, Artificial intelligence, Annual optimisation, District heating and cooling, Heat-sharing network


1 複数建物を有する街区

❖ 熱源プラントの機器運用最適化




2 ニューラルネットワーク

- ❖ 予測値: 蓄熱槽最下層温度
- ❖ 入力値は下記の2つを設定
 - 1) 日中最大蓄熱量 [kWh]
 - 2) 15時~19時までの残存蓄熱量 [kWh]:
- ❖ 4種類の回帰モデルを比較
 - 1) 重回帰分析(MLR)
 - 2) m-PSO: 最適化手法による係数同定
 - 3) Curve fitting toolbox (CF): MATLAB
 - 4) ニューラルネットワーク(ANN)
- ❖ 結果
ANNが最も高い精度を示した。これにより、計算時間を短縮することが可能。



予測結果比較



従来制御と最適制御における各機器のCOP

3 最適化による効果

- ❖ 従来制御: 定格COPの良いものから順に運転、蓄熱槽は夜間蓄熱・日中放熱
- ❖ 最適制御: ε DE-RJにより出力を自由に操作可能
- ❖ 最適化により定格COPの良し悪しだけでなく、部分負荷率毎の機器効率をそれぞれ勘案し運転することが可能になった。
- ❖ 機器特性の非線形性が強いターボ冷凍機(CR1, 2, 3)及びガスヒートポンプ(GHP1, 2)のCOPが従来制御よりも格段に良い