

ヒューマンファクターと人工知能を用いた次世代建物設備システムの開発

Development of the Next Generation BACS Using AI and Human Factors

田中 規敏 Kitoshi Tanaka*¹ 菊池 卓郎 Takuro Kikuchi*²
高井 勇志 Takeshi Takai*³ 粕谷 貴司 Takashi Kasuya*⁴

梗概

クラウドやIoT (Internet of Things) の普及, GPU などのコンピュータリソースの増大はAI (Artificial Intelligence) 適用の可能性を広げている。本稿では, 筆者らが開発したAIを用いたヒューマンファクターの抽出と, 建物設備システムの遠隔制御, それらを実現するデータプラットフォームの概要について述べる。ヒューマンファクターとしては, カメラによる人物検知および着衣量の取得を行った。また, クラウドに収集した建物設備, IoT のデータを元に学習を行う強化学習エンジンを照明・空調の制御に適用した。システムの実績データとシミュレーションとの比較によって, 照明で15%以上, 空調で10%以上の省エネルギー効果があることを確認した。

キーワード: クラウド, ヒューマンファクター, AI, IoT, 空調・照明制御

Summary

The spread of cloud computing and the Internet of Things (IoT), as well as the increase in computer resources such as GPUs, are expanding the possibilities for the application of Artificial Intelligence (AI). In this paper, we outline our AI-based human factor extraction, remote control of building equipment systems, and the data platform that enables them. As human factors, the authors used cameras to detect people and acquire the clothing insulation value. In addition, a reinforcement learning engine, which learns based on the building equipment and IoT data collected in the cloud, was applied to control lighting and air conditioning systems. Comparison of the system's actual data with simulations confirmed energy savings of more than 15% for lighting and 10% for air conditioning.

Keywords: cloud, human-factor, AI, IoT, building automation system

1 はじめに

クラウドが普及し, 様々なデバイスがネットワークにつながるIoT (Internet of Things) や, 統計や機械学習などの技術を使って大量のデータから知見を得ようとするビッグデータの技術の普及により, 高度な制御や分析に関するサービスが, クラウド環境で安価に提供される環境が整いつつある。一方, 建物設備においては, カーボンニュートラル実現のため省エネルギー技術の更なる高度化が求められるとともに, 細かい環境の動きを捉えることで入居者の快適性を上げたり, 建物管理人材の不足から, 遠隔・自動化によって負荷の軽減をしたりするニーズが高まってきている。筆者らは, このようなニーズに対応すべくヒューマンファクターと人工知能を用いた次世代建物設備システムの開発に着手した。本報ではこのシステム概要および竹中技術研究所で実証試験を行った結果について報告する。

2 システム概要

開発したシステム構成をFig. 1に示す。本システムは, ①建物設備システム群, ②ヒューマンファクターの抽出

*1 技術本部 技術プロデュース部 チーフエキスパート Chief Expert, Technology Producing, Technology Department

*2 技術研究所 主任研究員 博士(工学) Chief Researcher, Research & Development Institute, PhD

*3 技術研究所 主任研究員 博士(情報学) Chief Researcher, Research & Development Institute, PhD

*4 情報エンジニアリング本部 チーフエンジニア 博士(情報理工学) Chief Engineer, ICT Engineering Division, PhD

等を行うIoTセンサー・システム群、③ゲートウェイ、④データプラットフォーム（ビルコミ）、⑤建物制御用AI学習エンジン（強化学習エンジン）の5つのコンポーネントから構成されている。①②から、概ね1分毎の粒度で計測値や設定値等を取得し、③を介してクラウドに構築されている④にデータが送信される。それらのデータは、現在値がリアルタイムで⑤から参照されるとともに、内部のビッグデータ処理基盤に保存され、⑤の学習のために提供される。⑤は保存されたデータを元に学習を行い、更にリアルタイムの計測値・設定値を元に、様々な制御を試行しながら学習を行う強化学習を行うシステムである。なお、⑤からの制御コマンドは、④が有するAPI（Application Programming Interface）を介して③に伝えられ、更に現地設備の通信仕様に変換された上で、①にリアルタイムに伝えられる。詳細については参考文献¹⁾に譲る。

本システムは、竹中技術研究所（千葉県印西市）にて運用されている²⁾。本建物は、延床面積39,150m²の研究棟・管理棟・実験棟で構成され、約200名の研究員が執務しており、2019年に一人ひとりの創造性の高まる空間への建築・設備改修を実施し、「新価値創造力の向上」を目指した改修が行われた。開発システム導入にあたり、上記改修では対象としていなかった熱源制御の遠隔制御ポイント等の追加、ヒューマンファクターの抽出に利用するカメラ、ゲートウェイの設置を行った。以降では、開発システムの中でも人の位置や姿勢、着衣量といったヒューマンファクターの抽出技術と、AIを利用した建物設備制御の実証結果について述べる。




Fig. 1 システム構成
System configuration

3 ヒューマンファクターの抽出

3.1 システム概要

複数台のネットワークカメラで撮影した画像を元に、深層学習を用いて人の検出および位置推定、及び着衣量の推定を行うシステムを開発した。カメラは、Fig. 2に示す360度全周囲が撮影可能な天井設置型の小型モデルを採用し、少ない台数で広範囲を撮影することによって圧迫感の少ない撮影環境を実現している。効率よくシステム開発を進めるために既存の学習済みモデルを活用しているが、これらは透視投影レンズ（いわゆる普通のカメラレンズ）によって撮影した画像を用いて学習しているため、歪みのある魚眼レンズの画像をそのまま入力として用いると推論精度が大幅に低下してしまう。そこで、撮影した全周画像を複数の透視投影画像に展開して推論し、その結果を統合する処理を加えている（Fig. 3）。取得頻度は1分毎である。




Fig. 2 ネットワークカメラ
Network camera




Fig. 3 全周画像の展開とAIによる推論例
Expansion of fish-eye image and example of AI inference

3.2 人の検出と位置、着衣量推定

人の検出には、公開されている学習済みモデル（ssd_inception_v2_coco³⁾）をベースモデルとし、本

研究のために準備した教師データセットを用いて、ファインチューニングを行って学習したモデルを用いた。Fig. 4に教師データの例を示す。教師データセットの内容は、20～60歳代の男女についてオフィス内で取り得る姿勢や服装に特化した画像に対して、人の領域（全体・上半身・下半身）それぞれの矩形と、服装のラベル付けを行ったものである。

また、人検出で得られた矩形領域に対して、頭、肩、肘、手首、腰、膝、足首等の位置を推定する姿勢推定を導入することで、より正確な足元位置が分かるようになり、元の空間中での人位置の推定精度の向上を図っている。姿勢推定も公開されている学習済みモデル（human-pose-estimation-0001⁴⁾）を用いた。Fig. 5に姿勢推定結果の一例を示す。立位、座位といった状態も推定することが可能であるため、より詳しい建物利用者情報を取得することができる。




Fig. 4 教師データの例
Example of training data



Fig. 5 姿勢推定（人物特徴点検出）の結果
Results of pose estimation
(Person feature point detection)




Fig. 6 各月の人数カウントの時系列変化
Time-series changes in the number of occupants for each month




Fig. 7 推定位置のヒートマップ
Heat map of occupants

Fig. 6に居室利用人数の時系列変化を示す。評価対象期間は、2020年12月1日～2021年10月31日とした。図より、人数カウント値は1月～3月が小さいことが読み取れる。これらは、技術研究所が位置する千葉県に新型コロナウイルス感染症拡大に伴う緊急事態宣言が発令されていた期間（2021年1月8日～3月21日）に一致しており、出社を控え在宅勤務などの対応を取っていたことによる。また、各月とも昼12時頃に人数カウント値の減少がみられるが、これは建物利用者が昼休憩時間に食事のため離席していると考えられる。一方で夜間に複数人が検知されていることは建物の利用実態と一致しておらず、カメラ画像を確認したところ、19時以降建物の照明が消灯されることにより画像の分析精度が低下して誤検知が増加していることがわかった。特に人数カウント値の大きい10月について、建物利用者の推定位置をヒートマップ表示した結果をFig. 7に示す。これより座席の周囲に位置推定結果が集中していることがわかる。また、当建物では新型コロナウイルス感染症対策のため着席位置を対角にする運用が行われており、実際に建物利用者が対角上に着席していることも確認でき、位置推定がおおむね妥当な結果であると考えられる。

各カテゴリの学習およびテスト画像枚数および正答率(%)									
カテゴリ	襟付きシャツ 長袖	襟付きシャツ 半袖	シャツ 長袖	シャツ 半袖	シャツ ノースリーブ	ワンピース 長袖	学習枚数	テスト枚数	計
学習枚数	1,224	1,109	298	938	61	85	5,820	573	77.49
テスト枚数	115	120	25	98	4	3			
正答率(%)	80.87	76.67	64.00	78.57	50.00	100.00			
カテゴリ	ワンピース 半袖	ベスト	セーター 長袖	トレーナー 長袖	カーディガン 長袖	タートルネック セーター	学習枚数	テスト枚数	77.49
学習枚数	70	68	273	146	178	34			
テスト枚数	10	3	29	15	12	4			
正答率(%)	90.00	33.33	79.31	46.67	41.67	50.00			
カテゴリ	ジャケット 長袖	ロングコート	ハーフコート	ジャンパー	ウィンド ブレーカー	ダウン ジャケット	学習枚数	テスト枚数	77.49
学習枚数	718	219	135	91	4	169			
テスト枚数	73	19	18	3	2	20			
正答率(%)	87.67	78.94	66.67	100.00	0.00	95.00			

Fig. 8 着衣量推定モデルの精度
Accuracy of the clothing insulation value estimation model

着衣量の推定モデルについても、上記と同様のデータセットを作成し、DenseNet201⁵⁾をベースモデルとしてファインチューニングを行ったモデルを用いており、オフィスで想定される19パターンの服装(着衣量)を推定可能である。Fig. 8にテストデータ(573枚)に対する正答率を示す。学習画像が少ないと正答率は低くなる傾向が見られるが、平均正答率は77%であった。なお、本研究では上半身のみを推定対象としており、下半身は固定値として加算することで全身着衣量(clo値)を得ている。現状のアルゴリズムでは上半身と下半身の分離が難しいためであるが、オフィスにおいて下半身のclo値ほとんど一定であるため、概ね妥当と考える。

4 深層学習を用いた設備制御手法の開発

4.1 光環境制御への適用と効果検証

対象建物²⁾では、昼光利用しつつ照明消費電力を低減するために照明、ブラインド、ルーバーの制御に輝度制御システムを採用している。Fig. 9に示すように室内各所に輝度カメラを設置し、撮影画像から予め定めたエリア(窓面や壁面、床面など)の平均輝度を算出して、その平均輝度がエリア毎に定めた目標輝度範囲に収まるように各機器を制御している。この制御を便宜上、ローカル制御と呼ぶこととする。ローカル制御では、目標とする輝度範囲を超えた場合にエリア毎にどの機器をどの順番で動かすかルールを定めて制御しており、基本的にはブラインドまたはルーバーを操作した後、それでも輝度が目標範囲を外れる場合に照明調光率を変えて調整するシステムである。これに対して、本研究開発では、強化学習の手法を用いて過去データから学習したモデルを構築し、室内輝度が目標範囲に収まり、かつ電力消費量が最小となる行動を決定し、各機器を制御するものである。これをAI制御と呼ぶこととする。AI制御のモデル学習に用いた入出力データを整理したものをTable 1に示す。

Fig. 10にAI制御モデル概要を示す。本モデルは、2つのモデルを組み合わせで構築している。まず、蓄積した過去の運用データから室内輝度を予測する予測AIモデルを構築しており、これによりある状態の時にそれぞれの機器を様々に操作した場合の輝度をシミュレーションすることができる。予測AIモデルは決定木ベースのアルゴリズムであるLightGBM⁶⁾を使用した。また、機器の稼働状況(状態・行動)と電力消費量と輝度から求まる報酬(Table 1参照)の関係を過去データから学習し、最適な機器の運転方法を選択する強化学習AIモデルを構築している。強化学習AIモデルは、Actor-Critic系方策勾配法とQ学習の中間に位置する強化学習手法であるDDPG⁷⁾を使用した。これらのモデルは、2020年6月～2020年11月を学習対象期間として初期モデルを構築し、2021年1月より実環境で運用を開始し




Fig. 9 輝度制御システム
Light environment control based on brightness

Table 1 光環境AI制御モデルの入出力および報酬
Input / output and reward of AI model for light environment control

目的	①各エリアの平均輝度が目標輝度範囲内であること ②照明電力消費量の最小化
入力データ	太陽高度、太陽方位角、日射量、大気圧 調光率、ルーバー角度、ブラインド角度・高さ
操作対象(出力)	①照明調光率 ②ルーバー角度 ③ブラインド角度 ④ブラインド高さ 136point
報酬	報酬 = $-\Sigma(\text{照明電力消費量}^{*1} + \text{重み}\alpha \times \text{ペナルティ}^{*2})$ ※1…定格出力×器具数×調光率×係数にて算出した値 ※2…輝度が目標輝度範囲から外れた場合に、エリア内で操作する照明器
学習対象期間	2020年6月～2021年5月 (初期モデルは、2020年6月～2020年11月の期間で得られたデータを学習して構築し、2021年5月に再学習によりモデルを更新した)




Fig. 10 光環境AI制御モデル概要
Overview of AI model for light environment control




Fig. 11 ローカル制御とAI制御の輝度制御状況比較
Comparison of BAS and AI system with respect to brightness control

た。しかし、初期モデルに用いた運転データはルールベースで機器を制御するローカル制御の運転データが大半であり、データに隔たりがあったため、2021年5月に学習データを1年分（2020年6月～2021年5月）に拡充して再学習を行い、AIモデルを更新している。

本制御システムによる室内輝度の制御状況を検証した。Fig. 11にローカル制御とAI制御それぞれにおいて目標輝度範囲を外れた時間の割合を示す。制御エリアにより一長一短があるものの、ローカル制御でも目標輝度範囲を逸脱しやすいエリアはAI制御においても制御性が悪くなる傾向が見られ、AI制御はローカル制御に比べて目標輝度範囲を逸脱する時間が多くなっているエリアが見られた。特にトップライト下、窓面付近など日射の影響を受けやすいエリアにおいて目標輝度範囲を逸脱しやすい傾向が見られた。今回、報酬計算におけるペナルティの重み係数を全てのエリアで同一にしていたが、エリア毎に重み係数の修正を行う等の改善余地があると考えられる。

Fig. 12にAI制御を実施した場合とローカル制御で運転した場合の照明電力消費量を比較した結果を記す。対象期間は2021年1月～12月であり、AI制御の照明電力消費量は実測値を、ローカル制御の結果は日射量がほぼ同じであった日を選定し、集計したものである。天候により差異はあると考えられるが、15%～40%の削減効果が各月で見られ、年間照明電力消費量に対して約29%の削減効果があることがわかった。




Fig. 12 AI制御による省エネルギー効果
Energy saving effect by AI control system

4.2 空調制御への適用と効果検証

空調制御の対象として、本開発では、(1) 空調運転開始時刻の改善および(2) 熱源送水温度の最適化についてAIを用いた制御システムを構築した。

(1) 空調開始時刻の改善と効果検証

空調開始から室温が冷暖房適温（設定温度や管理温度）立ち上がりまでに要する時間は、気象状況や室内負荷状況、冷温水温度などによって異なるため、冷暖房負荷状況に応じて空調機起動時間を調整することで省エネルギーが図れる（Fig. 13参照）。多くの建物ではスケジュール運転により、起動時間を一定としていることが多く、就業開始時刻よりも早くに適温まで立ち上がって無駄な空調時間となってしまうことがあるが、外気や室温、熱源・空調機の運転状況から空調開始時刻の適切な調整を実施することで空調エネルギー消費量を削減できると考えられる。

本開発では、データプラットフォームに収集した様々なデータから、就業開始時刻までに適温となり、かつ省エネルギーとなる最適な空調開始時刻を予測するAIモデルを開発し、その効果を検証した。

Table 2にAIモデルの入出力データを整理したものを示す。対象建物は、スケジュール運転により毎日6時に空調を開始しており、就業時刻は8時30分までに




Fig. 13 空調開始時刻の改善
Improvement of air conditioning start time

Table 2 空調開始時刻予測AIモデルの入出力
Input / output of AI model for air conditioning start time

目的	無駄な空調運転時間の削減
入力データ	外気温湿度、日射量、降雨、日没信号 各空調機の冷温水熱量、送水温度、平均温度（各階）、 平均湿度（各階）、空調機稼働状況、時刻、休日フラグ
モデル	LightGBM
予測項目	空調を稼働しない場合の8時室温を予測 ※設定温度（冷房：26℃、暖房：22℃）に達するか否かを判定
操作対象（出力）	各空調機の発停
学習対象期間	2020年6月～2020年10月

室温が適温になるように運用していた。そこで、開発システムでは終業時刻30分前の8時に室温が適温となるように空調開始時刻を自動調節することを目標とした。構築したAIモデルは、外気や室内温湿度、供給熱量、空調稼働状況などを特徴量とし、8時の各階平均温度を予測する。室温予測は6時～8時の間10分ごとに行っており、冷房時は適温を超える場合には空調運転を開始するようにデータプラットフォームを介して自動制御に指令を送ることとした。予測モデルは冷房、暖房で室温挙動が異なるため、それぞれ別にモデルを作成する必要があるが、実証建




Fig. 14 室温予測値と実績値の比較
Comparison of room temperature predicted value and actual value




Fig. 15 空調開始時刻調整時における空調電力消費量の変化
Changes in air conditioning power consumption when the air conditioning start time is adjusted

物は居室が1階～3階まで吹き抜けており、暖房時において室温が適温まで上昇するのに時間を要し、空調開始時刻を遅らせることによる効果がないため、以降では冷房時における結果について詳述する。

Fig. 14にAIモデルの予測値と実測値を比較した結果を示す。図中の凡例は、予測した時刻を示しているが、予測時刻によらず概ね8時の室温を $\pm 0.5^{\circ}\text{C}$ 以内で精度良く予測できることがわかる。

Fig. 15に、6時に空調を開始する通常制御とAI制御により空調開始時刻を遅らせて場合の空調電力消費量の時系列変化の一例を示す。どちらの制御においても空調起動時は配管内水温や室内状況により負荷が大きいため、電力消費量の変動が大きい。起動から1時間程度経過すると変動が緩やかに推移することがわかる。そこで、空調開始時刻の遅延によって得られる省エネルギー効果を次の式で計算することとした。

$$\begin{aligned} & \text{空調開始遅延による空調電力削減量 (kWh)} \\ &= \text{空調開始1時間後～2時間後の電力消費量 (kWh/h)} \times \text{遅延時間 (h)} \end{aligned}$$

Fig. 16に、空調開始時刻の適正化による年間省エネルギー効果を試算した結果を示す。AI制御時における電力消費量は実績値であり、通常制御の電力消費量はAI制御時における空調電力削減量は前述の計算式により求め、実績値に加算することで求めた値である。中間期における削減率が大きく、6時～9時の空調電力消費量に対して20～30%程度の削減効果があることがわかる。また、夏期においても2～5%程度の削減効果があった。この削減量は、冷房期間全体における空調電力消費量に対して1.8%程度の削減量であった。

(2) 熱源送水温度の最適化

Fig. 17に熱源システムのCOPと送水温度の関係を示す。COPは、熱源が生成する冷温水熱量／熱源システム（ポンプ動力含む）電力消費量で定義され、熱源効率を示す指標である。冷房時を例に見ると、熱源システムのCOPは、送水温度を高くするほど大きくなり、高効率に、つまり省エネルギーに運転することがわかる。ただし、送水温度を上げすぎると、室内を冷房あるいは除湿できなくなり、室内環境を悪化させる。このことから、AIモデル設計においては、熱源システムの消費電力を最小化しつつ、対象エリアにある各部屋の




Fig. 16 空調開始時刻の適正化による省エネルギー効果
Energy saving effect by optimizing the air conditioning start time




Fig. 17 熱源システムのCOPと送水温度の関係 (左：冷房時、右：暖房時)
Relationship between COP of HVAC system and water supply temperature (left : during cooling, right : during heating)

室温及び湿度が維持できるように報酬や制約条件を設けた。

Table 3にAIモデルの入出力データを整理したものを示す。本モデルでは、複数ある部屋の設定温度と実際の室温の差をペナルティとして設定し、ペナルティに重みを乗じた値と熱源システムの電力消費量の和に-1を乗じたものを報酬として設計した。光環境制御同様にLightGBMを使用して教師あり学習を行い、この報酬を予測するモデルを構築している。また、送水温度を決定する方法は、この予測モデルを用いて複数の送水温度を選択した場合の報酬をそれぞれ予測し、最も報酬が大きくなる送水温度を選択した。なお、予測した報酬が同じ値になった場合は、それらの送水温度の中央値を選択することとした。本モデルで制御を実施する際は、制御間隔を30分とし、6時～18時の空調運転時間を対象に効果を検証した。また、報酬を最大化するように予測するものの、室内環境が悪化するような状況（室温が設定温度から乖離する、または除湿できない等）になった際には強制的に送水温度を戻すルールを適用し、室内環境の快適性を維持している。

AI制御による年間省エネルギー効果を把握するため、実証建物において1年間運用した。Fig. 18にAI制御を実施した場合と通常制御で運転した場合の熱源システム電力消費量を比較した結果を示す。

ここで、AI制御の消費電力は実績値であるが、通常制御の消費電力は計算値である。すなわち、AI制御時と同じ熱負荷を処理する場合について過去の運転データから得られる送水温度と熱源システムCOPの関係やポンプ効率を元に、冷房時は冷水7℃、暖房時は温水45℃一定で運転したものとして計算した。

図よりAI制御によって省エネルギー運転が実現できていることがわかり、冷房期間においては14.4%、暖房期間で8.1%の削減率であり、年間熱源電力消費量に対して10.6%の熱源電力量が削減できる結果であった。なお、冷房期間の省エネルギー効果には、前節の空調開始時刻の改善も含めた結果である。冷房に比べて暖房時における削減率が小さいが、これは対象とした熱源機の特性による。前述の熱源システムのCOP特性と送水温度の関係からわかるように、暖房時は冷房時に比べ送水温度の変化によるCOPの向上効果が小さいためである。

5 まとめ

スマートビルディングを実現するために、情報を一元化するデータ連携基盤を構築し、実際に稼働中のオフィスに対して、利用者の情報を取得する技術、および、快適性を保ちつつエネルギー使用を最小化する設備機器制御技術を適用して、1年以上に渡ってデータを取得し、分析、検証を行った。

ヒューマンファクター抽出では、従来にはなかったオフィスを想定した着衣量のデータセットを作成し、学習済みモデルをファインチューニングすることで開発コストを抑えて人の位置、姿勢、着衣量を推定可能なシステムを構築した。今後、これら利用者情報を利用し、設備連動制御や空間の使われ方を分析するアプリケーション開発へ展開することが考えられる。また、AIを利用した建築設備制御では、データプラットフォームから取得できる運用データを元に機械学習を用いた設備制御システムを構築し、1年間運用して省エネルギーと室内環境を両立する制御を実現できることを確認した。

謝辞

本研究における成果は国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の助成事業の結果得ら

Table 3 熱源送水温度制御AIモデルの入出力および報酬
Input / output and reward of AI model for water supply temperature

目的	①室内温度が設定温度±2℃以内であること ②熱源電力消費量の最小化
入力データ	外気温湿度、日射量、降雨、日没信号 各空調機の冷温水熱量、室内温度、相対湿度、室温設定値
操作対象 (出力)	熱源送水温度
報酬	報酬 = $-\Sigma$ (熱源システム電力消費量 ^{*1} + 重み α × ペナルティ ^{*2}) ※1…制御対象エリアは、建物全体の熱源が供給する負荷の一部であったため、各空調機の熱量、冷温水流量を集計し、実測値を元に作成した熱源COP特性およびポンプ動力特性から電力消費量を計算した。 ※2…設定室温と実際の室温の差
学習対象期間	冷房：2020年6月～2020年9月、暖房：2020年11月～2020年12月




Fig. 18 AI制御による省エネルギー効果
Energy saving effect by AI control system

れたものである。

参考文献

- 1) 粕谷貴司ら：「futaba：スマートビルのためのビッグデータ・プラットフォーム」, 情報処理学会論文誌, 62巻, 3号, p.867-876, 2021年
- 2) 樋口祥明ら：「特集 竹中技術研究所リニューアルプロジェクト 人の多様性に配慮した研究施設リニューアルの計画と評価」, 竹中技術研究報告 No.76, 2020年12月
- 3) <https://supervise.ly/explore/models/ssd-inception-v2-coco-1861/overview>
- 4) https://docs.opencv.org/2020.3/_models_intel_human_pose_estimation_0001_description_human_pose_estimation_0001.html
- 5) G. Huang, et al.: Densely Connected Convolutional Networks. IEEE Conference on Pattern Recognition and Computer Vision (CVPR), 2016.
- 6) Guolin Ke, et al.: LightGBM: A highly efficient gradient boosting decision tree. In Advances in Neural Information Processing Systems, pages 3149–3157, 2017.
- 7) David Silver, et al.: Deterministic policy gradient algorithms, in Proc. of the 31st ICML, Vol.32, pp.387-395, 2014