

doi:10.11835/j.issn.1000-582X.2021.01.007

基于人群密度估计的空调末端及新风量分级调控方法

李彤月, 孟月波, 刘光辉, 徐胜军, 纪 拓

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

摘要: 负荷估计是空调系统优化控制的关键一环, 人员移动的随机性和不确定性, 使得建筑空间人员负荷难以准确估计, 导致现有控制策略控制效果欠佳, 系统响应不及时, 滞后性大, 造成能源浪费以及建筑内部环境热舒适性降低。针对该问题, 提出一种基于人群密度估计的空调末端及新风量分级控制策略。首先, 采集建筑空间图像信息, 建立多列卷积神经网络人群密度估计模型, 获取人员数量及动态分布, 计算人员实时负荷; 其次, 引入人员负荷控制因子, 提出空调分级调控策略, 实现空调末端及新风供给。实验结果表明, 方法能够更好地维持建筑内部热环境稳定, 系统响应速度更快, 具有较好的节能潜力。

关键词: 人群密度估计; 负荷计算; 空调能耗; 分级控制

中图分类号: TP181

文献标志码: A

文章编号: 1000-582X(2020)01-057-10

Air conditioning terminal and new air volume classification control based on crowd density estimation

LI Tongyue, MENG Yuebo, LIU Guanghui, XU Shengjun, JI Tuo

(College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, P. R. China)

Abstract: Load forecasting is a key part of system optimization control of air conditioning system, and the randomness and uncertainty of personnel movement make it difficult to accurately estimate the load of building space personnel, resulting in poor control effect of existing control strategies, the slow response of the system, the waste of energy and the reduction of thermal comfort of the building interior environment. To solve these problems, an air conditioning terminal and new air volume classification control strategy based on crowd density estimation is proposed in this paper. Firstly, the image information of building space was collected and a model of multi-column convolution neural network crowd density

收稿日期: 2020-05-07

基金项目: 国家重点研发计划资助项目(2017YFC0704207-03); 国家自然科学基金面上资助项目(51678470), 陕西省自然科学基金面上资助项目(2020JM-473, 2020JM-473); 陕西省教育厅专项科研计划资助项目(18JK0477); 西安建筑科技大学基础研究基金资助项目(JC1703)。

This work was supported by National Key Research and Development Program (2017YFC0704207-03), General program of National Natural Science Foundation of China (51678470), General program of Natural Science Foundation of Shaanxi Province (2020JM-473, 2020JM-473), Special Research Project of Education Department of Shaanxi Province (18JK0477), Basic Research Foundation of Xi'an University of Architecture and Technology (JC1703).

作者简介: 李彤月(1994—), 女, 硕士研究生, 主要从事控制工程、计算机视觉方向研究, (E-mail) 18792760269@163.com。

通讯作者: 孟月波, 女, 副教授, 硕导, 主要从事控制工程、计算机视觉方向研究, (E-mail) mengyuebo@163.com。

estimation was established to obtain the number and dynamic distribution of personnel and calculate the real-time load of building space personnel. Secondly, the personnel load control factor was introduced and the air conditioning grading control strategy was put forward to realize the air conditioning terminal and fresh air supply. The experimental results show that the method proposed in this paper can better maintain the internal environment stability of the building, at the same time, the system has faster response speed and greater energy saving potential.

Keywords: crowd density estimation; load calculation; energy consumption of air conditioning; classification control

能源是现代社会运行和发展的重要驱动力,随着社会的发展,能源需求在全球范围内不断攀升,其中,建筑能源需求占有较大比重。中国建筑能耗占全球能源消耗的40%,其中,空调系统能耗占据大部分,大空间建筑的日趋增加,使得空调节能成为全球建筑能耗研究中的重中之重^[1-2]。

空调系统在控制过程中期望以最小能耗代价满足公共建筑内环境热舒适性要求,实现系统节能降耗,其中精确冷负荷预测是空调控制策略优化的关键之一。谢敏^[3]提出基于信息熵和变精度粗糙集优化的不确定支持向量机方法,实现中长期冷负荷预测;Seung Jin Oh, Kermanshahi B^[4-5]等根据建筑长期冷负荷电力消耗,采用神经网络,支持向量机,随机森林等算法,预测未来时间段内电量需求;Xu等^[6]提出基于非线性回归与外源输入(NARX, nonlinear autoregressive with external input)神经网络和反向传播神经网络(BP, back propagation)的建筑物冷负荷短期预测方法,利用上海的气候数据对两种模型进行实验与分析;Yu等^[7]提出基于云的建筑管理系统(BMS, building cooling sysoem)架构,构建语义分析模型,实现建筑物冷却系统(BCS)的短期冷负荷预测;Zhang等^[8]建立GA-SVR和GA-WD-SVR预测模型,使用气象数据中前一天和前一小时的冷负荷记录作为模型输入,输出第二天的系统运行策略以及下一小时的制冷负荷,进行办公楼的短期和超短期冷负荷预测。上述方法考虑了确定性冷负荷因素,以此获取系统设计参数,改善系统滞后和供需不匹配问题。但是,实际空调系统的大部分负荷因素是不确定的,尤其是人员因素。传统的空调控制策略中大都忽略人员负荷的不确定性以及随机性,导致实际冷负荷曲线偏离设计的预测曲线。

Hoes^[9]等提出了利用室内人员的行为信息作为空调的最佳启停指标之一,徐小燕^[10]等把室内人员行为信息和自然免费资源结合起来,采用神经网络模型对建筑中自然通风、空调系统进行联合优化,建立空调系统的最优停机过程,得到了一条性能较好的最优策略;上述方法中都考虑了空调系统中的人员负荷对建筑能耗的影响,并表明建筑内部人员负荷信息对于消除能源浪费,提高人员热舒适性至关重要。但是,由于人员因素的不确定性以及不规则运动,人员负荷的实时检测并不容易。Sun Z^[11]、Mattias Gruber^[12]、Nassif N^[13]、Ansanay-Alex G^[14]等采用CO₂浓度水平来估算建筑内部人员的实时占用情况,然而CO₂稀释过程缓慢,建筑内部存在大量的CO₂来源以及建筑内部的过度通风,都会使得CO₂检测建筑内部人员数量与实际人员数量的一致性之间存在差异,同时,CO₂传感器的部署成本非常高。Wang W^[15]、Wei W^[16]、Aravind K^[17]等利用Wi-Fi网络,通过人员接入建筑内部网络信号,检测人员实时占有情况;但是,该方法有一定的局限性,例如由于建筑物几何形状以及各种干扰信号,导致网络不稳定或延迟,难以实时检测接入数量预测人员负荷,同时,由此引起的隐私问题成为该方法未能推广的关键。

近年来,机器视觉技术与深度学习的迅速发展,为复杂场景下的人员检测提供了新的技术手段^[18-20],并取得了良好的效果。将图像作为“软传感器”,提出了一种基于人群密度估计的空调末端及新风量分级控制策略。首先,采集建筑空间图像信息,利用MCNN(single-image crowd counting via multi-column convolutional neural network)^[21]网络人群密度估计模型,获取人员数量及动态分布,计算建筑空间人员实时负荷;其次,引入人员负荷控制因子,提出空调分级调控策略,实现空调末端及新风供给。

1 建筑空间人员负荷实时估计方法

1.1 人群密度估计模型

有效实时的人员检测是建筑人员负荷准确估计的前提条件,图像以其直接、真实、快速的特点,为人员检测提供了新的方法。商场,体育馆,机场等公共大建筑场景图像背景复杂,仅采用场景图像的局部特征或者全局特征不能有效解决不同密度的复杂人群估计问题,而基于深度学习的多尺度人群密度估计方法,不仅能够把图像的局部特征和全局特征有效融合在一个表示框架中,表达更加复杂的图像信息,并解决了尺度变化问题,计算复杂度低。因此,采用深度学习,建立一个多列卷积神经网络的人群密度估计模型 MCNN,进行建筑内部人员密度检测,获得建筑内部实时人员负荷。

MCNN 模型结构如图 1 所示,首先,采用三列卷积神经网络(CNN, convolutional neural networks)对场景图像进行特征提取,三列 CNN 分别对应 3 个不同大小的感受野(大,中,小),使得每个 CNN 能对由于透视或不同的图像分辨率造成的人头大小变化进行自适应,之后将三列子网络的特征图用一个 1×1 的卷积进行线性加权,得到该图像的人群密度图。

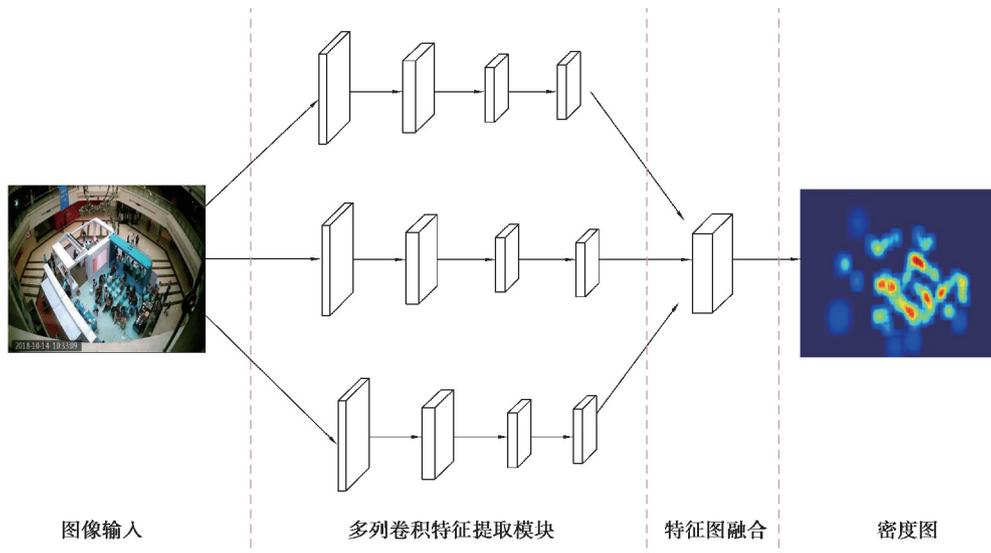


图 1 检测模型结构框图

Fig. 1 Block diagram of the detection model

CNN 估计人数的常用方法有两种:1)输入图像直接输出估计的人头数;2)输入图像得到人群密度图(人/ m^2)。采用第二种方法,因为 CNN 模型学习密度图时,学习到的滤波器更适应透视效果显著变化的任意输入图像,拥有更多的语义特征,人群计数的准确性更高。为了使得到的密度图能够更好适应不同视角、不同人头大小、不同人群密度的输入图像,采用公式(1)的方法,计算输入图像 x 的人员密度图,网络训练采用公式(2)所示损失函数。

$$F(x) = \sum_{i=1}^N \delta(x - x_i) \times G_{\sigma_i}(x), \text{ with } \sigma_i = \beta \bar{d}^i, \quad (1)$$

式中: x_i 表示人头在图像中的像素位置; $\delta(x - x_i)$ 表示图像中人头位置的冲激函数; $G_{\sigma_i}(x)$ 表示高斯核; N 为图像中的人头总数; $\bar{d}^i = \frac{1}{m} \sum_{j=1}^m d_j^i$ 为距离 x_i 人头最近 m 个人头与该人头的平均距离(通常情况头部的大小与 2 个相邻的人在拥挤场景中的中心之间的距离有关; \bar{d}^i 在人群较密集情况下近似等于人头大小),实验中 $\beta=0.3$ 。

$$L(\theta) = \frac{1}{2N} \sum_{i=1}^N \|F(x_i; \theta) - F_i\|_2^2, \quad (2)$$

式中: θ 是待优化的网络参数; N 是训练图片数目; x_i 表示输入图像; F_i 表示 x_i 对应密度图的真值; $F(x_i; \theta)$

表示由 MCNN 生成的密度图。

1.2 负荷动态估计

通过建立的 MCNN 人群密度模型,通过公式(3)计算当前建筑内部的人员数量。

$$N_{px} = \int F(x_i; \theta) dx, \quad (3)$$

式中: $F(x_i; \theta)$ 为 MCNN 模型生成的人员密度图; N_{px} 是当前图像内的人员数量。

根据建立的 MCNN 人群密度估计模型,通过公式(4)即可计算建筑空间动态人员实时负荷变化。

$$Q(t) = kN_{px}(t)q, \quad (4)$$

式中: $Q(t)$ 为 t 时刻建筑空间内的动态人体负荷; $N_{px}(t)$ 为室内 t 时刻总人数; k 为群集系数, q 为人体负荷指标, $w/\text{人}$ ^[22]。

基于 MCNN 模型的人员负荷实时估计方法,解决传统负荷计算的滞后性以及复杂性问题,更直观,方便得到当前建筑内部由人员密度变化带来的负荷变化,为进一步空调系统的调控提供了技术手段。

1.3 MCNN 人员密度估计模型实验及结果分析

面对大型建筑空间的复杂背景,图像会产生不同光照,不同角度,遮挡等问题,研究在某万达商场场景对提出的人员密度估计模型进行验证,模型检测结果如图 2 所示。

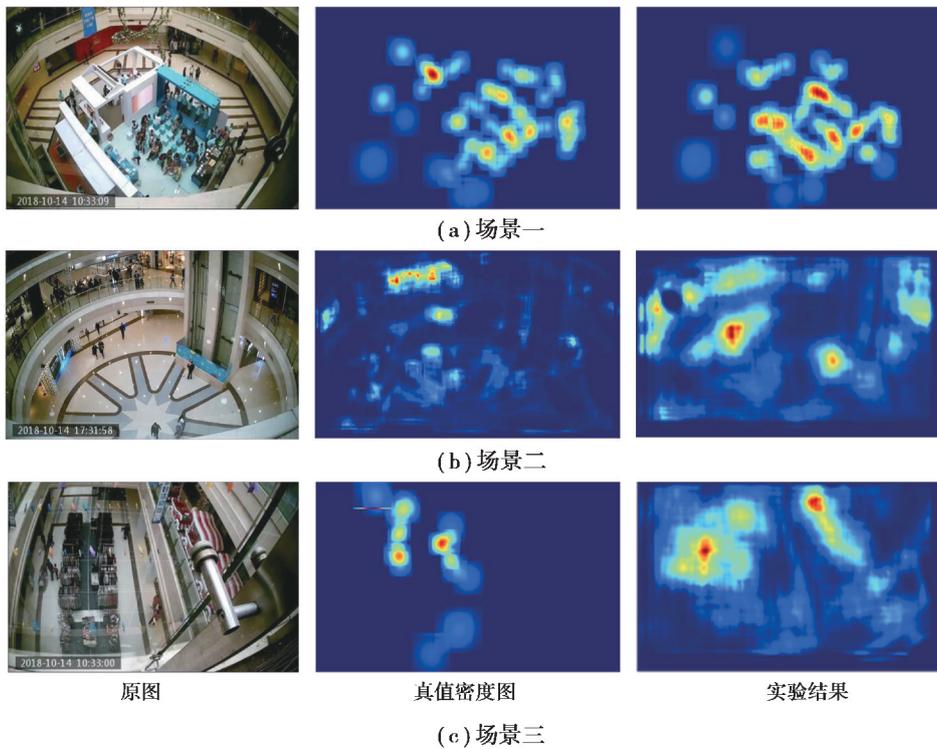


图 2 MCNN 模型检测结果

Fig. 2 MCNN model detection results

采用平均绝对误差(MAE, mean absolute error)和均方误差(MSE, mean square error)^[23] 2 个评价指标定量分析 MCNN 模型的检测效果,其中 MAE 主要反映预测值和真值之间的误差,MSE 表示网络预测结果的准确性,反映估计量与被估量之间差异程度,具体详见公式(5)、(6)。评价结果如表 1 所示,相比传统检测方法,模型在复杂场景下的检测精度拥有明显优势。

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |z_i - \hat{z}_i|; \quad (5)$$

$$\text{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (z_i - \hat{z}_i)^2}, \quad (6)$$

式中: N 表示测试图像数目; z_i 是第 i 张图片实际人数; \hat{z}_i 是算法估算人数。

表 1 MCNN 模型评估
Table 1 MCNN model evaluation

MCNN 模型评价指标	万达数据集		
	场景一	场景二	场景三
MAE	7.37	7.69	7.91
MSE	11.79	12.36	12.57

同时,图 3 给出了 MCNN 模型在万达数据集不同场景,不同时间段检测到的人数与实际人数统计对比图,由结果可知,提出的人群密度估计模型检测到的人数与真实统计人数相比,准确度达到 90%,有效估计建筑空间中人群密度。

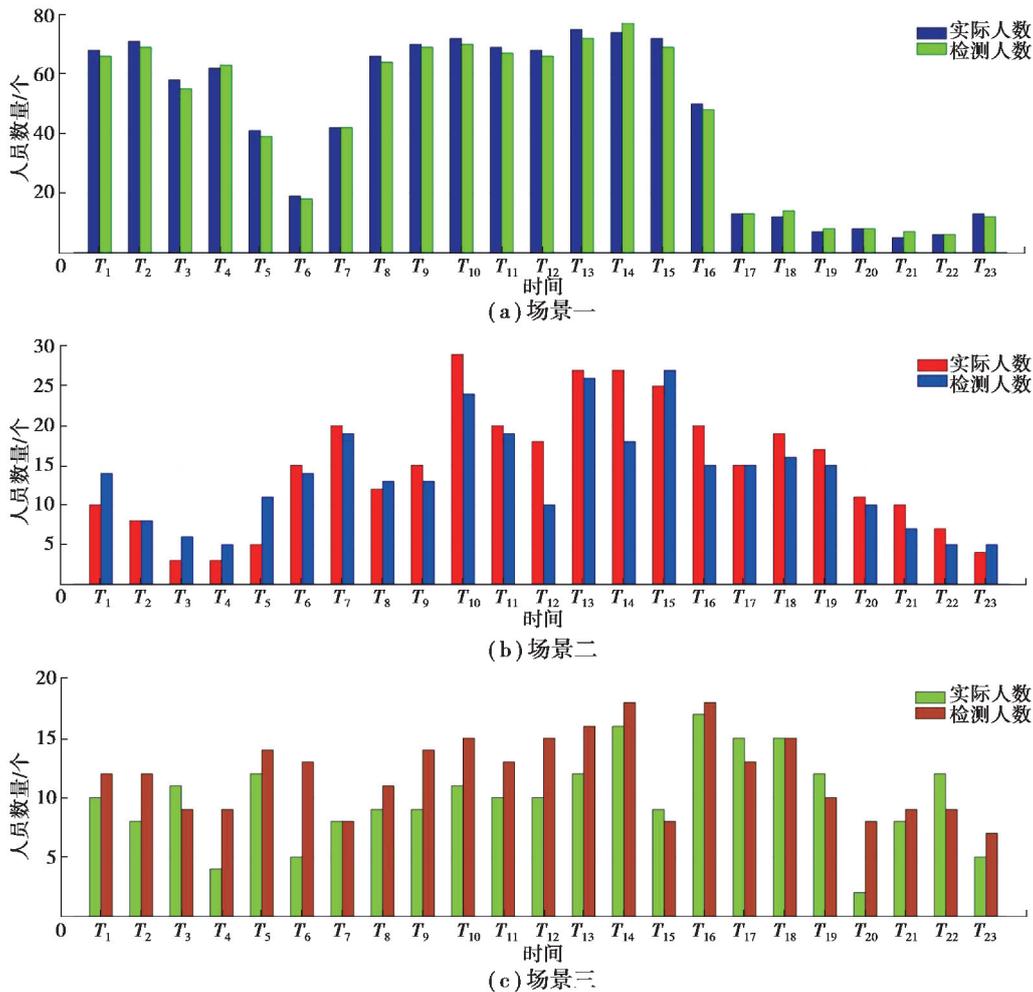


图 3 建筑空间人群密度估计对比结果

Fig. 3 Comparison result of crowd density estimation in building space

2 空调末端及新风量分级控制策略

2.1 空调分级控制策略

空调系统控制为串级控制,包括外环温度控制部分、内环冷量控制部分。外环温度控制部分根据建筑内部检测温度与设定温度之间的差值,输出系统所需冷量;内环冷量控制部分根据外环控制输出的系统所需冷量值,调节空调末端的风阀/水阀开度,改变供冷量,使室内温度保持在设定范围。

但是,由于公共建筑人流量变化大,空气热惯性大,由此产生的传感器响应延迟(如因空气导热因素产生

的温度传感器响应延迟等)造成传统温湿度、CO₂ 传感器等对人员负荷变化导致的室内负荷变化的检测存在较大时滞,进而造成外环温度控制部分输出的系统所需冷量不能准确反映室内负荷变化,导致常规空调控制系统响应不及时,滞后性大,同时建筑内部热舒适性不佳,能源浪费较大。

为解决以上问题,提出基于人群密度估计的空调末端分级控制策略,如图 4 所示。空调末端分级调控方法是在原有空调控制策略基础上增加分级控制策略。首先,利用机器视觉与深度学习技术,建立 MCNN 人员密度检测模型,计算实时建筑内部人员密度变化,据此进行人员负荷等级划分;根据负荷等级,确定空调系统当前的分档冷量设定值;将其与外环温度控制部分输出系统所需冷量相加,作为内环冷量控制部分的最终输入,以此控制风阀/水阀开度,实现建筑内部环境的温度控制。

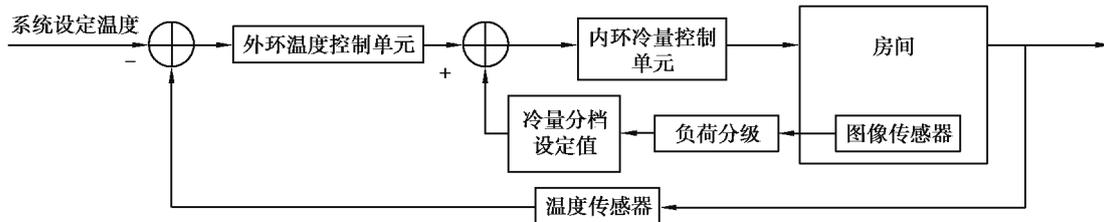


图 4 基于人群密度估计的空调末端分级控制策略原理图

Fig. 4 Schematic diagram of air-conditioning grading control strategy based on real-time estimation of personnel density inside the building

提出的空调分级控制策略设定每 5 min 对建筑空间内图像信息进行一次分析,检测建筑空间内人群密度。为简化后续控制策略,避免设置的档位过多导致控制设备的投入增大,将人群密度划分为低、中、高三类,不同密度人群对应不同等级室内负荷,具体如表 2 所示。定义当人群密度在 0~0.4 人/m² 时,建筑空间中人的负荷较低,对应负荷等级为 I 级;当人群密度在 0.4 人/m²~1.0 人/m² 时,建筑空间中人的负荷中等,对应负荷等级为 II 级;当人群密度大于 1.0 人/m² 时,建筑空间中人的负荷最大,对应负荷等级为 III 级。

根据表 2 估计负荷档位,确定对应的冷量设定值,并在一定时间内维持冷量给定(实验环境下,设定为 25 min),然后切换为常规控制方法。当检测到室内负荷档位发生变化,重新确定冷量设定值。

表 2 人群密度与室内负荷等级划分

Table 2 Crowd density and indoor load level division

密度分类	人群密度(人/m ²)	室内负荷等级
低	0~0.4	I
中	0.4~1.0	II
高	>1.0	III

基于同样原因,常规新风控制策略也无法跟随负荷变化实时调节新风量供给,因此,按照表 2 的人群密度与室内负荷等级划分方式,对新风量采用与空调末端相同的分级控制思想,在保证舒适度的前提下,降低能源的浪费。与常规空调控制方法相比,此方法能够基于视觉技术迅速估算当前室内环境参数,并据此调节空调冷量与新风量输出,提高系统对人员负荷变化扰动的响应速度,改善常规控制方法大滞后导致的室内环境品质问题。

2.2 实验结果与分析

以西安建筑科技大学智能建筑环境技术实验平台(IBETEP)的空调控制系统为实验研究平台。该实验研究平台为变风量空调系统,具体由 2 台冷水机组、1 台变频泵、1 台热水箱(含加热器)、2 台空气处理机组(AHU, Air-handling units),以及 6 个变风量末端(VAVBOX)、若干散流器、管道和各种传感器、控制器、执行器、工控机等控制单元设备组成。另外,引入空间图像的监控设备,估算室内人员实时负荷,据此调节空调系统末端及新风量供给。

在实验平台上,基于 Visual C++ 技术实现了图像的处理算法及分析软件,通过 OPC 技术和 IBETEP

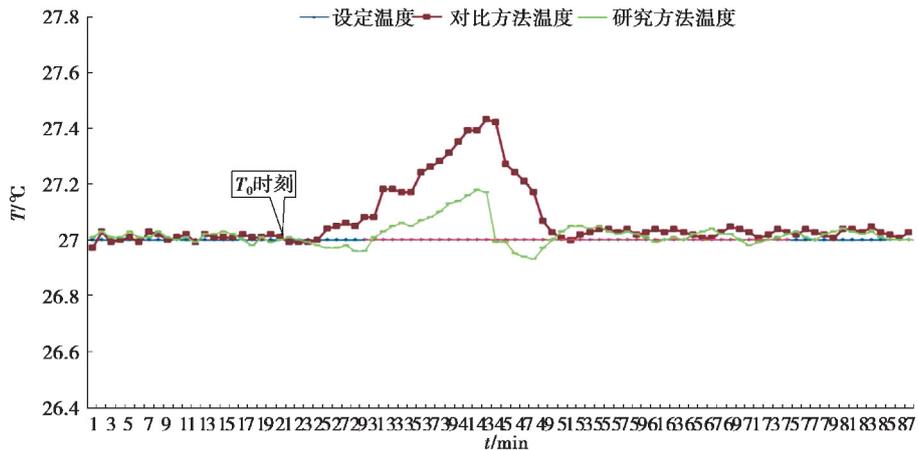
空调控制系统进行控制数据的传输。

实验环境设定为:室外温度为 35.8 °C,供回水压差 0.15 Bar,空调机组送风温度 19 °C,送风压差 115 Pa,室内温度为 27 °C。

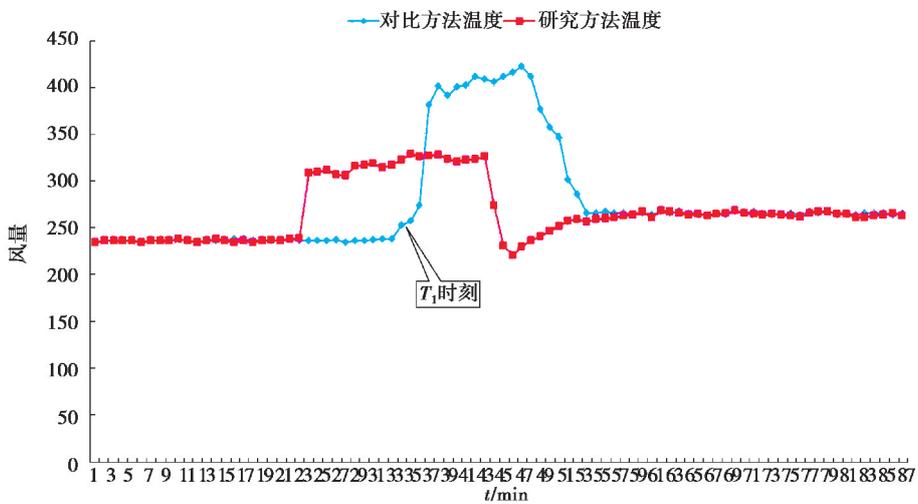
2.2.1 空调末端实验结果分析

在实验研究过程中,分别采用两种控制策略进行对比分析。一种为常规 PID 控制策略,在这种基准方式下,通过人工设定室内回风温度、送风温度,利用温度传感器检测实际回风温度、送风温度,控制空调的送风量。另一种方式采用控制策略。通过机器视觉与深度学习技术,建立 MCNN 人员密度检测模型,计算人员密度变化,进行人员负荷等级划分;将根据负荷等级确定的分档冷量设定值与外环温度控制部分输出的系统冷量值相加,作为内环冷量控制部分的最终输入,控制风阀/水阀开度,实现建筑内部环境的温度控制。

当测试空间室内温度保持平稳后,在 T_0 时刻(如图中所示)室内人员由 0 人增加到 8 人。采用常规 PID 方法和提出方法进行调节时,室内的温度变化和空调末端风量对比曲线分别如图 5(a)、(b)所示。由图 5(a)可以看出,常规方法下,人员进入测试空间后的相当一段时间内虽然室内温度开始爬升,但风量的调节一直比较缓慢,直到 T_1 时刻风量才开始显著增大(图 5(b)所示),稍后室内温度开始下降,最终趋于设定值。反映出传统控制方法下由于空间热惯性和系统固有延迟,系统响应滞后较大。系统在室内人员负荷增加的极短时间内(如图 5(b)所示),迅速增大室内送风量,使得室内温度变化较为平缓,且温度峰值明显小于常规控制方式。和常规控制方法相比,实验结果反映出研究方法能够根据室内负荷的实时变化动态调整控制量的输出,具有较快的响应速度,避免了常规方法由于检测的滞后性导致的建筑环境品质下降,拥有更好的建筑热舒适性,且更加节能。



(a) 温度变化曲线



(b) 风量变化曲线

图 5 温度、风量变化曲线

Fig. 5 Temperature or Air volume change curve

在 T_2 时刻(如图中所示)室内人员由 0 人增加到 12 人,重复上述过程。室内的温度变化和空调风量的对比曲线分别如图 6(a)、(b)所示。实验结果进一步验证了前面的分析结果。

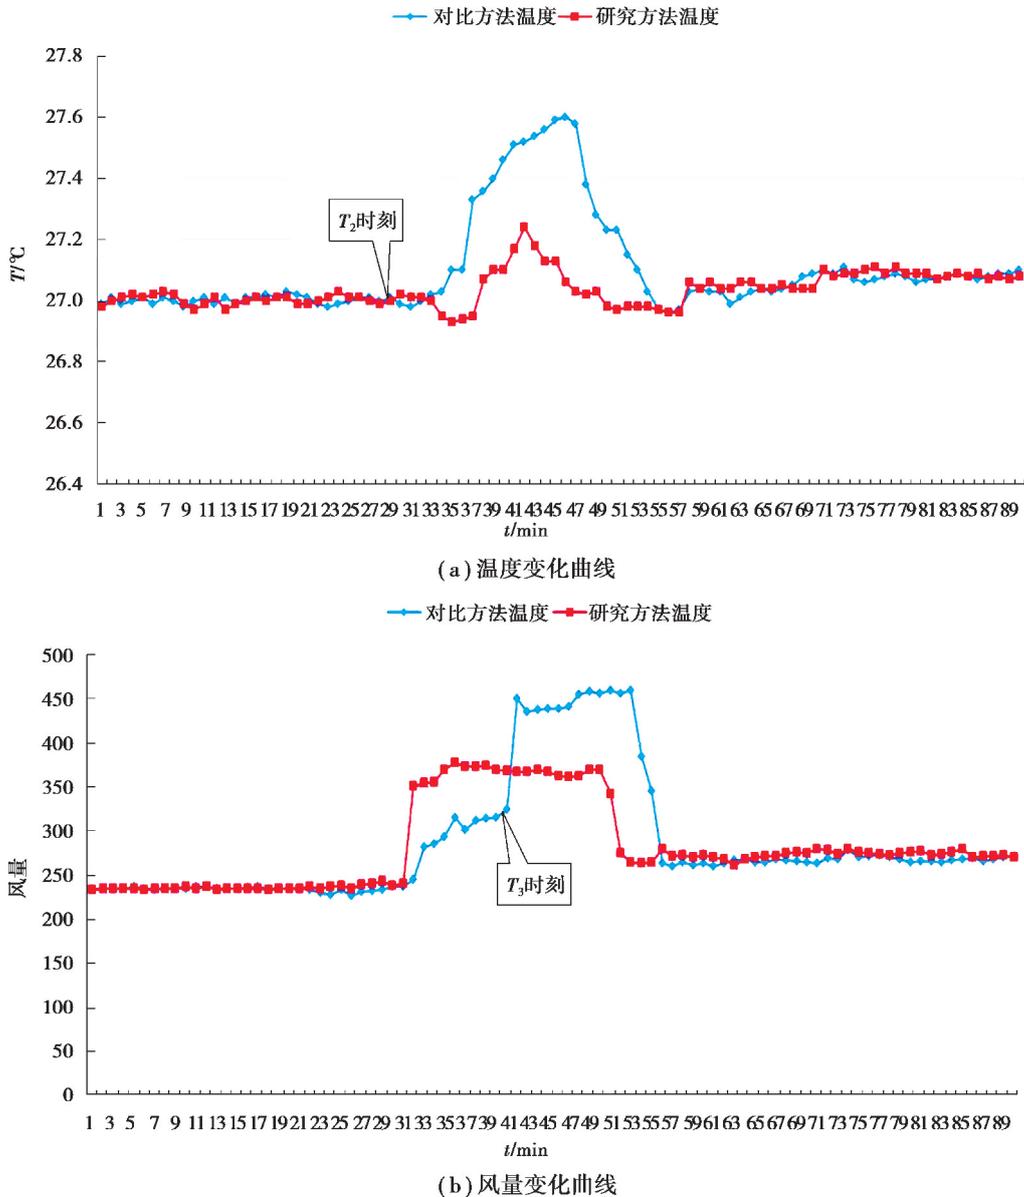


图 6 温度、风量变化曲线

Fig. 6 Temperature or Air volume change curve

2.2.2 新风量分级控制实验结果分析

验证了跟随室内人员数量的变化,按照实际需求进行新风量大小的调节。当测试空间内人员负荷分别为 0 人、8 人、12 人的情况下,空调系统依据图像信息分析人员密度结果,自动实施中央空调新风档位调整,给定 3 档位工作模式:10%新风比、20%新风比和 30%新风比。在不同新风比档位下,中央空调冷水泵功率如图 7 所示。

由实验结果可知,10%新风比时,空调冷机负荷最小,平均 514.06 kW/h, 20%新风比时,平均 538.74 kW/h, 30%新风比时,空调冷机负荷最大,平均 577.06 kW/h,由此可见,冷机功率随着新风占比的增加而增加,和 10%新风比时相比,平均功率增加了 12.26%。因此可以发现,在不同负荷下,调整新风比对于空调系统的节能有很大的潜力。对于提出的空调控制方法,由于能够根据实际室内负荷实时估计实现新风量的按需供给。与采用固定新风比的常规方法相比,当室内负荷较小时,提出的控制方法在不影响室内热舒适度的前提下,

可以根据新风负荷的变化实时动态调节新风占比,减小新风的供给,实现按需供气,从而实现中央空调系统的节能减排。

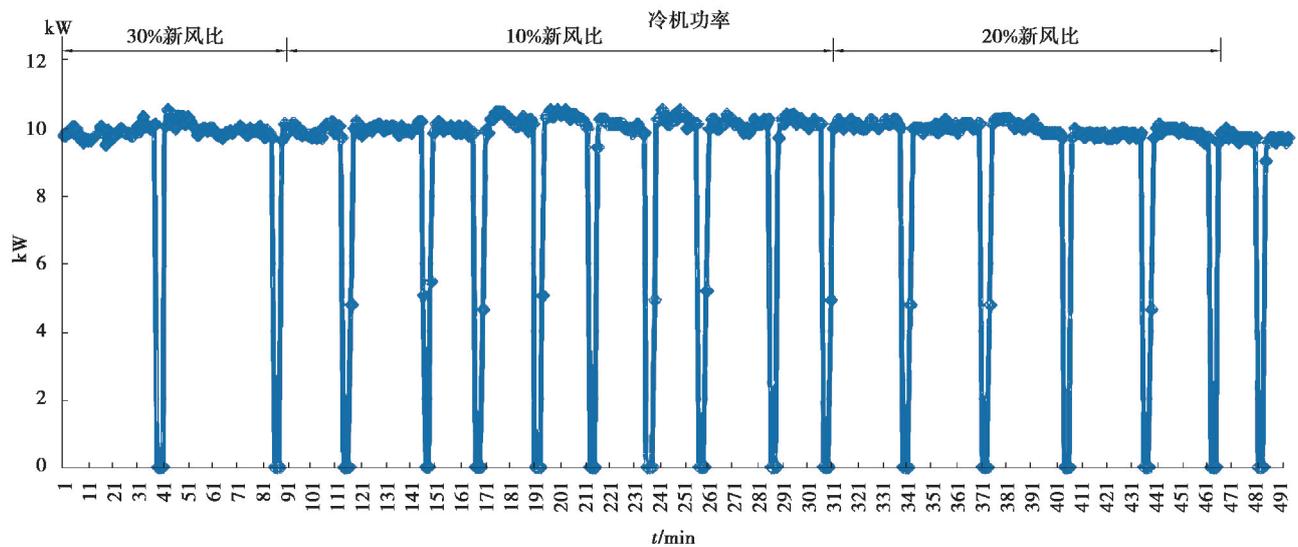


图 7 在不同新风比档位下,中央空调冷水泵功率

Fig. 7 The power of the central air conditioning chilled water pump at different fresh air ratios

3 结 论

提出一种基于人群密度估计的空调末端及新风量分级控制策略,将图像作为“软传感器”,采用深度学习方法,实现人群密度的实时估计,进而计算人员动态负荷,并在此基础上加入人员负荷控制因子,采用分级调控思想进行空调末端及新风量控制。实验结果表明,研究方法有效解决常规空调控制方法的滞后问题,缩短了系统的调节时间,提高了热舒适性,减少能源消耗。

参考文献:

- [1] 清华大学节能中心. 中国建筑节能年度发展研究报告[M]. 中国建筑工业出版社, 2018, 46(04): 133.
Tsinghua University Energy Conservation Center. China building energy efficiency annual development research report [M]. China Building Industry Press, 2018, 46(04): 133. (in Chinese)
- [2] 周欣, 燕达, 张野, 等. 空调系统需求特性对过量供应程度的影响[J]. 建筑科学, 2015, 31(10): 79-84+161.
Zhou X, Yan D, Zhang Y, et al. The influence of demand characteristics of air conditioning system on excess supply degree[J]. Architecture Science, 2015, 31(10): 79-84+161. (in Chinese)
- [3] Min X, Jia L D, Xiang J I, et al. Cooling load forecasting method based on support vector machine optimized with entropy and variable accuracy roughness set[J]. Power System Technology, 2017.
- [4] Oh S J, Ng K C, Thu K, et al. Forecasting long-term electricity demand for cooling of singapore's buildings incorporating an innovative air-conditioning technology[J]. Energy and Buildings, 2016; S037877881630442X.
- [5] Kermanshahi B, Iwamiya H. Up to year 2020 load forecasting using neural nets[J]. International Journal of Electrical Power & Energy Systems, 2002, 24(9): 789-797.
- [6] Xu Y L, Chen H X, Guo W, et al. A comparison of narx and bp neural network in short-term building cooling load prediction[J]. Applied Mechanics and Materials, 2014, 513-517: 1545-1548.
- [7] Yu J, Bae M N, Bang H C, et al. Cloud-based building management systems using short-term cooling load forecasting[C]//2014 IEEE Globecom Workshops (GC Wkshps). Atlanta; IEEE, 2014.
- [8] Ding Y Z, Qiang Y, Tian H. Research on short-term and ultra-short-term cooling load prediction models for office buildings[J]. Energy and Buildings, 2017, 154(Nov.): 254-267.
- [9] Hoes P, Hensen J, Loomans M. User behavior in whole building simulation[J]. Energy and Buildings, 2009, 41(3):

295-302.

- [10] 徐小燕, 管晓宏, 李黎. 建筑空调系统最优停机时间预测与控制[J]. 西安交通大学学报, 2013, 47(10): 31-36. (in Chinese)
Xu X Y, Guan X H, Li L. Prediction and control of optimal downtime of building air conditioning system [J]. Journal of Xi'an Jiaotong University, 2013, 47(10): 31-36. (in Chinese)
- [11] Sun Z, Wang S, Ma Z. In-situ implementation and validation of a CO₂-based adaptive demand-controlled ventilation strategy in a multi-zone office building[J]. Build Environ, 2011(46): 124-133.
- [12] Gruber M, Trüschel A, Dalenbäck J. CO₂ sensors for occupancy estimations: potential in building automation applications [J]. Energy Build, 2014(84): 548-556.
- [13] Nassif N. A robust CO₂-based demand-controlled ventilation control strategy for multi-zone HVAC systems[J]. Energy and Buildings, 2012 (45): 72-81.
- [14] Ansanay-Alex G. Estimating occupancy using indoor carbon dioxide concentrations only in an office building: a method and qualitative assessment[C] // 11th Rehva World Congress "Energy Efficient, Smart and Healthy Buildings", Prague: Clima, 2013.
- [15] Wang W, Wang J, Chen J, et al. Multi-zone outdoor air coordination through Wi-Fi probe-based occupancy sensing [J]. Energy and Buildings, 2018, 159: 495-507.
- [16] Wei W, Jiayu C, Tian Z H. Occupancy prediction through machine learning and data fusion of environmental sensing and Wi-Fi sensing in buildings[J]. Automation in Construction, 2018, 94: 233-243.
- [17] Aravind K, Mikkilineni, Jin D, et al. A novel occupancy detection solution using low-power IR-FPA based wireless occupancy sensor[J]. Energy and Buildings, 2019, 192: 63-74.
- [18] Zou J H, Zhao Q C, Yang W, et al. Occupancy detection in the office by analyzing surveillance videos and its application to building energy conservation[J]. Energy and Buildings, 2017, 152: 385-398.
- [19] Krizhevsky A, Sutskever I, Hinton G E. imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60: 84-90.
- [20] Zhang C, Wang X. Cross-sense crowd counting via deep convolutional neural networks[C] // 2015 IEEE Conference on Piscataway, NJ: IEEE, 2015: 833-841.
- [21] Zhang Y Y, Zhou D S, Chen S Q, et al. Single-image crowd counting via multi-column convolutional neural network[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition. [S.L.]: IEEE, 2016: 589-597.
- [22] 赵荣义, 范存养, 薛殿华. 空气调节[M]. 北京: 中国建设工业出版社, 2008: 52-53.
Rong Z Y, Fan C Y, Xue D H. Air conditioning [M]. Beijing: China Construction Industry Press, 2008: 52-53. (in Chinese)
- [23] Tseng F M, Yu H C, Tzeng G H. Combining neural network model with seasonal time series ARIMA model[J]. Technological Forecasting and Social Change, 2002, 69(1): 71-87.

(编辑 侯 湘)