BIBLID 0350–1426 (206)

Pregled metoda mašinskog učenja u sistemima klimatizacije, grijanja i hlađenja

Review of machine learning methods in heating, ventilation and air-conditionig systems

Milica KAŠIKOVIĆ*, Univerzitet u Istočnom Sarajevu, Fakultet za proizvodnju i menadžment Trebinje, Republika Srpska, Bosna i Hercegovina

Aleksandar ANĐELKOVIĆ, Univerzitet u Novom Sadu, Fakultet tehničkih nauka, Novi Sad

Ključne riječi: *klimatizacija; grijanje i hlađenje; mašinsko učenje; neuronske mreže*

Potrošnja energije u sektoru zgradarstva predstavlja značajan procenat ukupne primarne energije koja se u većini zemalja troši zbog potrošnje sistema klimatizacije, grijanja i hlađenja. Smanjenje povezane potrošnje energije uz održavanje ugodnih uslova u zgradama konfliktni su ciljevi i predstavljaju tipičan problem optimizacije koji zahtjeva inteligentno projektovanje sistema. Takođe, potrebne su i preciznije i brže metode za otkrivanje i dijagnostiku kvarova tih sistema. Metode vještačke inteligencije i mašinskog učenja imaju veliki potencijal u tom pogledu, posebno sa razvojem informacionih tehnologija i senzorske opreme, omogućavajući pristup velikim količinama visokokvalitetnih podataka. Bez obzira na to, mašinsko učenje još nije potpuno prihvaćeno u industriji. U radu je dat prikaz nekih metoda mašinskog učenja koje se mogu koristiti u sistemima klimatizacije, grijanja i hlađenja, a te metode se klasifikuju na nadgledano, nenadgledano i podržano učenje. U nastavku je dat literaturni pregled metoda i modela zasnovanih na mašinskom učenju za poboljšanje optimizacije i kontrole u pomenutim sistemima, kao i mogućnosti primjene u oblasti otkrivanja i dijagnostike kvarova. Prikazane su prednosti i nedostaci metoda mašinskog učenja i date neke smjernice za dalji tok istraživanja u ovoj oblasti.

Key words: *heating; ventilation and air conditioning; machine learning; neural networks*

Energy consumption in the building sector represents a significant percentage of the total primary energy consumption in most countries due to the energy consumption of heating, ventilation and air conditioning systems. Reducing the associated energy consumption while maintaining comfortable conditions in buildings are conflicting goals and represent a typical optimization problem that requires intelligent system design. Also, more precise and faster methods are needed for the fault detection and diagnosis in these systems. Artificial intelligence and machine learning methods have great potential in this regard, especially with the development of information technology and sensor equipment, allowing access to large amounts of high-quality data. Nevertheless, machine learning is not yet fully accepted in the industry. The paper gives an overview of some machine learning methods that can be used in heating, ventilation and air conditioning systems, and these methods are classified into supervised, unsupervised and reinforcement learning. Below is a literature review of methods and models based on machine learning to improve optimization and control in the mentioned systems, as well as the possibilities of application in the field of fault detection and diagnosis. Advantages and disadvantages of machine learning methods are presented and some guidelines for further research in this area are given.

Uvod

Stambene, poslovne i druge zgrade čine oko 35% ukupne potrošnje finalne energije i oko 26% ukupnih povezanih emisija CO_2 [1]. Za postizanje održivog dugoročnog razvoja i nižih emisija ugljenika veoma je važno smanjenje potrošnje energije u sektoru zgradarstva. Energija koja se troši samo na klimatizaciju, grejanje i hlađenje – KGH, (eng. Heating, Ventilation and Air Conditioning - HVAC) iznosi 35%–65% ukupne energije, prema vrsti zgrade [2]. Tipičan raspored potrošnje energije u javnim zgradama je KGH – 60%, osvjetljenje – 17%, potrošnja tople vode – 16% i kuvanje – 9% [3]. Na osnovu navedenog može se vidjeti da sistemi KGH imaju značajan potencijal za smanjenje potrošnje energije, što sa jedne strane predstavlja ekonomsku motivaciju, a sa druge je korisno za životnu sredinu.

Optimizacija i kontrola sistema KGH se postiže kroz smanjenje utrošene energije i poboljšanje toplotnog komfora. Faktori koji utiču na toplotni komfor se klasifikuju u faktore životne sredine (temperatura, relativna vlažnost i brzina vazduha), i ljudske faktore (izolacija odjeće, brzina metabolizma, mogućnost adaptacije, pol, starost). Razvoj privrede i društva dovodi do porasta stepena toplotne ugodnosti, a istovremeno se razvija i kolektivna svijest o emisijama ugljenika i očuvanju životne sredine.

* *Corresponding author: milica.kasikovic@fpm.ues.rs.ba*

Mašinsko učenje je skup alata dizajniranih za izdvajanje informacija iz podataka, preoblikovanje podataka, učenje složenih obrazaca i donošenje informisanih odluka. On čini algoritamsko jezgro vještačke inteligencije (eng. Artificilal Intelligence – AI). Mašinsko učenje je brzo napredovalo posljednjih godina, vođeno prvenstveno većom dostupnošću podataka, pristupom sve većoj računarskoj moći i budžetima, kao i teorijskim napretkom. Takođe je došlo do razvoja senzorskih tehnologija (koji omogućavaju preciznija mjerenja), Interneta stvari (Internet of Things – IoT), tehnologije oblaka (čini skladištenje podataka praktičnijim i pouzdanijim), razvoja hardverske tehnologije, i novo ili poboljšano programiranje.

Različite metode vještačke inteligencije i mašinskog učenja se sve više primjenjuju u svim sektorima pa tako i u oblasti grijanja i hlađenja, ventilacije i klimatizacije. Korištenjem metode mašinskog učenja mogu se smanjiti troškovi, poboljšati energergetska efikasnost i kvalitet vazuha. U oblasti klimatizacije, grijanja i hlađenja ove metode se najviše koriste za upravljanje enrgetskim tokovima, otkrivanje kvarova, prediktivno održavanje, kontolu vazduha u zatvorenom prostoru i za projektovanje i planiranje sistema KGH u zgradama.

Postoji više preglednih radova koji su istraživali primjenu metoda vještačke inteligencije i mašinskog učenja [2, 4–12]. U ovom radu je dat pregled i kratak uvod u različite tipove mašinskog učenja i potencijalne primene mašinskog učenja u sistemima KGH.

2. Metode mašinskog učenja

Mašinsko učenje predstavlja jednu od najvažnijih oblasti u okviru vještačke inteligencije i bavi se proučavanjem, razvojem i dizajnom algoritama koji mogu da uče i vrše predviđanja na osnovu podataka. Podaci se koriste za stvaranje prediktivnih i deskriptivnih modela mašinskog učenja. Pored mašinskog učenja, u inženjerskim problemima se koriste i prepoznavanje obrazaca (eng. pattern recognition) i duboko učenje (eng. deep learning) kao metode vještačke inteligencije.

Duboko učenje je podoblast mašinskog učenja pri kome se karakteristike uče iz ponuđenih neoznačenih podataka. U zavisnosti od skupa podataka koji se koristi, mašinsko učenje se može podijeliti na nadgledano, nenadgledano i podržano učenje [13].

2.1. Nadgledano učenje

Cilj nadgledanog učenja (eng. supervised learning) se ogleda kroz formiranje modela za predviđanje ciljnog rezultata. Nadgledano učenje se zasniva na podacima koji imaju oblik ulaza i odgovarajućih izlaza (ciljeva), koji proizlaze iz nekog procesa. Nadgledano učenje koristi skup podataka za obuku, na osnovu koga model uči veze i odnose među podacima. Ova procedura procjene, koja se naziva „učenje“, zasniva se ili na minimiziranju greške (funkcija gubitka) između predviđanja i ciljeva, ili na maksimizaciji uslovne vjerovatnoće ciljeva, kao funkcije parametara. Ukoliko je cilj modela mašinskog učenja kontinuirano predviđanje ciljnih varijabli, zadatak se smatra regresijom.

Međutim ukoliko je cilj predviđanje diskretne ciljne varijable, za zadatak se kaže da je klasifikacija.

Uobičajene metode nadgledanog učenja uključuju linearnu regresiju, stabla odlučivanja, mašine za podršku vektorima (eng. support vector machine), algoritme k-najbližeg susjeda (eng. k-nearest neighbor), veštačke neuronske mreže (eng. artificial neural networks), skrivene Markovljeve modele, naivne Bajesove modele, modele Gausove mešavine, i Gausov proces, Gausov proces regresije i drugi modeli [2].

2.2. Nenadgledano učenje

Cilj nenadgledanog učenja (eng. unsupervised learning) je da iz skupa podataka formira klastere u kojima podaci pokazuju visok nivo bliskosti. Za razliku od nadgledanog učenja, nisu dostupne oznake za podatke i sistem sâm formira klastere iz ulaznih obrazaca. Nenadgledano učenje često se koristi za prethodnu obradu podataka prije primjene nadgledanog učenja. Polu-nadgledano učenje može se smatrati fuzijom nadgledanog i nenadgledanog učenja.

2.3. Podržano učenje

U okviru podržanog učenja nisu dostupne informacije o signalu željene kategorije ili eksplicitnih ciljeva. Od algoritma se očekuje da nauči optimalne ciljeve putem pokušaja i grešaka. U poređenju sa statičkim učenjem nadgledanih i nenadgledanih metoda, podržano učenje konstruiše vještačke agente koji preduzimaju različite akcije u datom okruženju kako bi dinamično učili, maksimizirajući kumulativne nagrade. Njegova najveća karakteristika je interaktivno učenje. Podržano učenje se uglavnom sastoji od agenta, njegovog okruženja, stanja, akcija i mehanizma nagrađivanja.

Duboko podržano učenje (eng. deep reinforced learning) koristi duboke neuronske mreže za učenje o politikama i postalo je popularno posljednjih godina.

Pored navedenog potrebno je istaknuti i transferno učenje (eng. transfer learning) i učenje sa više zadataka (eng. multi task learning). U okviru transfernog učenja podaci iz sličnog ili identičnog zadatka onom ciljnom zadatku, koriste se za prethodnu obuku modela (pronalaženje početnih vrijednosti za parametre i stoga specificiranje latentnog mapiranja) prije obuke na podacima specifičnim za zadatak.

U oblasti KGH, pristup mašinskom učenju generalno zahtijeva prethodno znanje ili označene podatke. Na osnovu toga, većina modela je zasnovana na nadgledanom učenju ili podržanom učenju, pri čemu se polunadgledano i nenadgledano učenje rijetko koriste.

Prediktivna kontrola zasnovana na modelu (eng. model pedictive control) stekla je veliku popularnost zbog mogućnosti formiranja naprednih algoritama upravljanja u zgradama za postizanje veće energetske efikasnosti i smanjenje emisije ugljenika. Bez obzira na to, i dalje se najviše koriste tradicionalne metode zasnovane na pravilima zbog visoke cijene metoda zasnovanim na modelu.

3. Metode mašinskog učenja za kontrolu i optimizaciju sistema KGH

Optimizacija sistema KGH se uglavnom sprovodi zbog smanjenja potrošnje energije sistema ili zbog povećanja ugodnosti korisnika. U prethodnom periodu mnogi istraživači su koristili metode i modele zasnovane na mašinskom učenju za kontrolu i optimizaciju sistema KGH, od kojih su neki navedeni u nastavku.

Yuan i sar. [14] su koristili kombinaciju metoda podržanog učenja i metoda kontrole zasnovane na podacima za optimizaciju rada sistema klimatizacije. Na osnovu jednogodišnjeg istraživačkog učenja, zaključili su da za dovod vazduha jedne zone podržanog učenja najbolje radi u pogledu nepovoljih vremenskih i ekonomskih troškova sistema. Pokazali su da se model podržanog učenja može koristiti u sistemima KGH, ali je potrebna velika količina podataka i interakcije sa okruženjem. Smatraju da je dugo vrijeme obuke modela podržanog učenja ograničavajući faktor u primjeni ove metode.

Chen i sar. [15] su formirali model zasnovan na podržanom učenju za koji su potrebni samo istorijski podaci kontrolera sistema KGH i nije potrebno nikakvo predznanje. Njihova

metoda pokazala se boljom od generičke strategije neuronske mreže.

Solinas i sar. [16] su radili poređenje tri pristupa zasnovana na podržanom učenju. Njihovi istraživanja pokazuju da je najbolji metod za smanjenje potrošnje energije i povećanje toplotnog komfora zasnovan na modelu bijele kutije. Smatraju da taj model prikazuje značajnu efikasnost, jer je potrebno svega nekoliiko mjeseci online učenja za poboljšanje enrgetske potrošnje, dok je toplotna ugodnost na istom nivou.

Deng i Chen [17] koristili model zasnovan na podržanom učenju za ponašanja i promjene termostata koji je modelovan procesom Markovljevih odlučivanja. Za formiranje modela koristili su tehnike Q-učenja. Ove tehnike koristili su i Chen i sar. [18] za kontrolu prirodne ventilacije za poboljšanje enrgeteske efikasnosti i ugodnosti korištenjem strategija podržanog učenja. Zaključili su da pored značajnih prednosti koje imaju metode podržanog učenja, nedostaci su to što zahtjevaju veliku bazu podataka i nemogućnost korišenja u drugim sistemima.

U mnogim istraživanja korištene su i vještačke neuronske mreže za kontrolu potrošnje energije i unutrašnjeg okruženja. Nasruddin i sar. [19] koristili su kombinaciju vještačkih neuronskih mreža i višeciljnog genetskog algoritma za optimizaciju rada rashladnog sistema. Koristili su više parametara od kojih su neki kontrola funkcije čilera, postavke termostata i pasivni solarni dizajn. Zaključili su da korištenjem se modela vještačkih neuronskih mreža dobija dobra korelacija između odluka i objektivnih funkcija. Takođe, smatraju da višeciljni genetiski algoritmi mogu obezbjediti dobre promjenljive alternativnog dizajna da bi se postigao optimalan rad sistema u smislu toplotne ugodnosti i potrošnje energije.

Arranz i sar. [20] su koristili LSTM (long short term memory) vještačke neuronske mreže za predviđanja potrošnje energije u sistemu KGH. Abida i sar. [21] su istraživali mogućnosti korištenja različitih vještačkih neuronskih mreža za optimizaciju i kontrolu sistema KGH. Oni su ispitivali kolika je tačnost tih modela, kao i razlike između modela sa jednim i više izlaza. Zaključili su da kontrola zasnovana na obradi podataka ima neka ograničenja, posebno kada su u pitanju ekstremni vremenski uslovi, ali je moguće dobiti bolje rezultate u prethodnu obradu podataka i različite konfiguracije.

Iako vještačke neuronske mreže mogu da daju veoma dobre rezultate predviđanja, ipak postoje i neki nedostaci, od kojih su najznačajniji veliki broj parametara, velika varijansa modela, problemi sa pretjeranim prilagođavanjem (eng. overfitting), kao i nedostatak sistemshih metoda arhitekture. Za rješenje nekih od ovih problema koriste se duboke neuronske mreže, a one zapravo podrazumjevaju vještačke neuronske mreže sa više skrivenih slojeva. Da bi se obezbjedilo precizno učenje potrebna je velika količina podataka. Ikeda i sar. [22] su korištenjem dubokih neuronskih mreža i višeslojne percepcije uspjeli da smanje dnevne operativne troškove u poređenju sa standardnom strategijom planiranja.

Spoj nadgledanog i podržanog učenja može dovesti do optimalnih rješenja za donošenje odluka o percepciji koji se odnose na složene sisteme. Zbog toga dolazi do razvoja dubokog podržanog učenja, što je zapravo kombinacija podržanog i dubokog učenja, a jedna od podoblasti mašinskog učenja.

Wei i sar. [23] koristili su metode dubokog podržanog učenja u obliku dubokog k-učenja za kontrolu sistema KGH. Korištenjem dubokih neuronskih meža obradili su veliku količinu podataka i prevazišni neke nedostatke algoritama asocijacije akcije stanja. Gupta i sar. [24] su predstavili mogućnost korištenja dubokog podržanog učenja za kontrolu sistema KGH i postizanje bolje toplotne ugodnosti i smanjenja troškova. Oni su radili i simulacije sa stvarnim vanjskim temperaturama vazduha i dobili veoma dobre rezultate.

Nguyen i sar. [25] su razvili okvir za kontolisano strategijsko učenje za sisteme KGH korištenjem metoda dubokog podržavanog učenja. Smatraju da korišenjem tog modela može doći do smanjenja potrošnje energije i povećanja kvaliteta vazduha u prostoru. Smatraju da je pristup korišenjem dubokog podržanog učenja znatno lakši od nekih konvencionalnih metoda za kontrolu rada sistema KGH.

Trenutni pristupi dubokog podržanog učenja prvenstveno tretiraju nestacionarnost okruženja zgrada na pasivan način, ometajući njihovu praktičnu primjenu. Potencijalno, duboko podržano učenje može ponovo naučiti dinamiku sistema, iako to oduzima mnogo vremena. Da bi prevazišli ovaj problem, Deng i sar. [26] su predložili novu metodu kontrole KGH, koja kombinuje aktivno otkrivanje promjene okruženja zgrade sa dubokim k-učenjem. Ovaj metod ima za cilj da aktivno identifikuje tačke promene okruženja zgrade kako bi se eliminisala nestacionarnost. Kontrola zasnovana na modelu pristupa nestacionarnosti preko nelinearne dinamike, a robusni i stohastički modeli su razvijeni upravo da bi se uzele u obzir nesigurnosti u dinamici.

4. Metode mašinskog učenja za postizanje ugodnosti

Unutrašnje okruženje utiče na život stanovnika u prostorijama. Postoji više faktora koji određuju ugodnost unutrašnje sredine, a najvažniji su toplotna ugodnost, kvalitet vazduha, osvjetljenje i buka. Među ovim faktorima najvažnija je toplotna ugodnost i mnogo više je proučavana u odnosu na druge faktore.

Faktori koji utiču na toplotnu ugodnost mogu se podijeliti u dvije grupe, a to su faktori životne sredine i ljudski faktori. Faktori životne sredine su temperatura, relativna vlažnost, brzina vazduha i srednja temperatura zračenja, dok su ljudski faktori toplotna otpornost odjeće i brzina metabolizma. Da bi se mogle koristiti metode mašinskog učenja, ovi faktori moraju biti mjerljivi.

Modeli mašinskog učenja za toplotnu ugodnost mogu sami da pronađu odnose između toplotnih povratnih informacija i varijabli i bez eksplicitnog znanja o fizičkim efektima svakog faktora. Modeli mašinskog učenja omogućavaju analitičaru da testira različite kombinacije inputa i pronađe najefikasniji parametar ili parametre. Štaviše, mašinsko učenje se može usvojiti i za modele zasnovane na proseku i za modele lične ugodnosti [27].

Wang i sar. [28] identifikovali su nekoliko problema, kao što su neujednačeni i divergentni istraživački objekti, različiti algoritmi mašinskog učenja, ograničene tehnike i resursi prikupljanja podataka, neujednačenost strukture podataka, istraživačke paradigme orijentisane na tehnologiju, neadekvatna prilagodljivost modela i nedostatak povjerenja korisnika. Pregled novijih primjena mašinskog učenja u studijama toplotne ugodnosti može pomoći istraživačima da identifikuju glavne nedostatke i potencijalne buduće oblasti proučavanja.

Luo i sar. [29] uporedili su performanse različitih algoritama mašinskog učenja i sugerisali da faktori kao što su tip zgrade, način rada zgrade i klimatski uslovi nisu među glavnim faktorima. Međutim, ti faktori mogu uticati na toplotnu percepciju stanara i zahtjevaju više istraživanja. Još jedna srodna oblast koja se može proučavati je primena modela mašinskog učenja u modelima lične ugodnosti i sistemima lične ugodnosti.

Ngarambe i sar. [30] su istraživali modele za predviđanje toplotne ugodnosti zasnovane na vještačkoj inteligenciji, energetske implikacije kontrola toplotne ugodnosti zasnovane na

vještačkoj inteligenciji, metode i algoritme mašinskog učenja za modelovanje toplotne ugodnosti. Njihov zaključak je sugerisao da podešavanje, tehnike optimizacije modela, primjenu modela udobnosti u sistemima upravljanja zgradama i kvantifikaciju prednosti sistema kontrole ugodnosti zasnovanih na veštačkoj inteligenciji treba dodatno proučavati.

Zhou i sar. [31] razvili su personalizovani model toplotne ugodnosti u kome se nelinearna regresija koristi za predviđanje personalizovanih metaboličkih stopa i temperature kože, koje se unose u fizički model toplotne ravnoteže zasnovan na povratnim informacijama koje daju stanari. Algoritam rješenja omogućava da se personalizovani model toplotne ugodnosti dinamički ažurira putem online proračuna. Uz kontinuirano ažuriranje modela, promjene u ugodnosti stanovnika mogu se pratiti i održavati visoku tačnost predviđanja. Autori su takođe razmotrili druge tehnike regresije, uključujući tehniku k-najbližeg susjeda, regresiju vektora podrške i stabla odlučivanja, otkrivši da k-najbližeg suseda daje najbolje performanse u smislu predviđanja termičkog glasanja.

Mašinsko učenje ima potencijal za značajno poboljšanje ugodnosti unutrašnjeg okruženja. Kroz raznovrsne metode, moguće je prilagoditi uslove prema potrebama korisnika, povećavajući tako njihovo zadovoljstvo i efikasnost sistema.

5. Primjena metoda mašinskog učenja za otkrivanje i dijagnostiku kvarova

Zbog složenosti i životnog veka sistema KGH, oni se često susreću sa raznim kvarovima i problemima, kao što su curenje rashladnog sredstva, kvarovi ventila i dr. Tradicionalne metode otkrivanja kvarova u ovoj oblasti često se oslanjaju na iskustvo i intuiciju profesionalnih tehničara, što ima mnoga ograničenja, kao što su niska efikasnost detekcije, nestabilni rezultati detekcije i visoki troškovi. Prema tome, otkrivanje i dijagnostika kvarova (eng. fault detection and diagnosis) ili automatizovana detekcija i dijagnostika kvarova mogu biti od ključne važnosti za obezbjeđivanje pouzdanog rada sistema i izbjegavanje rasipanja energije. Pod pojmom kvar podrazumijeva odstupanja od normalnog rada u najmanje jednoj mjerljivoj veličini, detekcija je otkrivanje kvara, a dijagnoza se odnosi na identifikaciju porijekla kvara kao i njegove lokacije [2].

Primjena metoda mašinskog učenja za otkrivanje i dijagnostiku hvarova u sistemima KGH postaje sve važnija u cilju povećanja efikasnosti, smanjenja troškova održavanja i poboljšanja ugodnosti.

Statističko praćenje procesa je metod za otkrivanje greške, koje se oslanja na multivarijantne podatke iz procesa da bi se pronašle anomalije, obično zasnovane na analizi glavnih komponenti ili parcijalnih najmanjih kvadrata. Analiza glavnih komponenti uobičajena je tehnika smanjenja dimenzionalnosti za podatke koji se nalaze u visokodimenzionalnom ambijentalnom prostoru.

Chen i sar. [32] su proučavali metode otkrivanja i dijagnostike kvarova zasnovanih na podacima u sistemima KGH, a to su modeli izgrađeni ili obučeni iz podataka putem mašinskog učenja ili metoda multivarijantne statističke analize. U radu je dat pregled literature sa tri aspekta: procesa, sistema koji se proučava (uključujući sisteme koji se istražuju, greške koje se identifikuju i povezane izvore podataka) i metrike evaluacije. Proces otkrivanja i dijagnostike kvarova zasnovan na podacima dalje je podijeljen na sljedeće korake: prikupljanje podataka, čišćenje podataka, prethodna obrada podataka, uspostavljanje osnovne linije, otkrivanje greške, dijagnostika grešaka i prognoza potencijalne greške. Autori smatraju da se metode otkrivanja i dijagnostike kvarova zasnovane na podacima i dalje suočavaju sa mnogim izazovima, kao što su primjena na realnim zgradama, evaluacija performansi, skalabilnost i prenosivost, interpretabilnost, sajber bezbednost i privatnost podataka, korisničko iskustvo itd.

Viol i sar. [33] su istakli da se većina istraživanja o transferu učenja za sisteme KGH fokusirala na algoritme učenja, ignorišući važnost odgovarajućih analiza sličnosti domena dostupnih podataka. Oni su predložili dizajn pristupa transfernog učenja zasnovanog na specifičnoj metodologiji odabira podataka. Procedura je podržana modelima neuronske mreže i analizom eventualnih neizvjesnosti predviđanja koje su rezultat procjene uzoraka ciljne aplikacije. Da bi se verifikovala predložena metodologija, ona se primjenjuje na polunadziranu studiju slučaja učenja o prenosu sastavljenu od dva javno dostupna skupa podataka klima-uređaja koji sadrže neke scenarije grešaka.

6. Zaključak

Veliki dio energije potrošene u zgradama koriste sistemi za klimatizaciju, grijanje i hlađenje, pa su ovi sistemi i jedan od izvora emisije ugljen-dioksida. Metode mašinskog učenja mogu doprinjeti optimizaciji i kontroli sistema KGH, kroz poboljšanje toplotne ugodnosti i smanjenje potrošnje energije i otkrivanju i dijagnostici kvarova. Različiti faktori utiču na izbor metode mašinskog učenja koja se primjenjuje, a neki od njih su: tip, količina i kvalitet podataka, cijena i složenost proračuna, a mnoge studije kombinuju različite metode radi postizanja što boljih rezultata.

Posljednjih godina se koriste i razvijaju duboke neuronske mreže, koje su veoma raznovrsne, imaju veliku preciznosti i koriste se na nenadgledane i nadgledane metode učenja. U optimizaciji i kontroli sistema KGH se u značajnoj mjeri koriste metode dubokog podržanog učenja, u okviru koga se kombinuju prednosti podržanog i dubokog učenja.

Dva najvažnija faktora u optimizaciji sistema KGH su ušteda energije i ugodnost korisnika. U pogledu očuvanja energije, većina studija ne razmatra cijene električne energije ili distribuirane i pametne mreže. Cijena električne energije varira, pri čemu se vršni period korišćenja sistema KGH često poklapa sa periodom vršne cijene električne energije.

Ugodnost u prostoru klasifikuje se na četiri osnovna faktora, a to su toplotna ugodnost, kvalitet vazduha, buka i osvjetljenje. Većina studija se fokusirana na toplotnu ugodnost, a neke razmatraju i kvalitet vazduha. Uglavnom se ne uzima u obzir stopa popunjenosti i aktivnosti stanovništva.

Literatura

[1] *** https://www.iea.org/energy-system/buildings, posjećeno septembra 2024.godine

[2] **Zhou, S. L., A. A. Shah, P. K. Leung, X. Zhu, Q. Liao,** A comprehensive review of the applications of machine learning for HVAC, *DeCarbon*, *2* (2023), 100023, https://doi.org/10.1016/j.decarb.2023.100023.

[3] **Carreras, J., J. Higuera, M. P. Alvarez, W. Hertog,** Hybrid smart lighting and climate control system for buildings, IET Conference on Future Intelligent Cities, Proceedings, 2014, https://doi.org/10.1049/ic.2014.0047.

[4] **Merabet, G. H., M. Essaaidi, M. B. Haddou, B. Qolomany, J. Qadir, M. Anan, A. Al-Fuqaha, M. R. Abid, D. Benhaddou,** Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques, *Renewable and Sustainable Energy Reviews*, *144*, 2021, 110969, https://doi.org/10.1016/j.rser.2021.110969.

[5] **Hong, T., Z. Wang, X. Luo, W. Zhang,** State-of-the-Art on research and applications of machine learning in the building life cycle, *Energy Build*. *212*, 2020, 109831, https://doi.org/10.1016/j.enbuild.2020.109831

[6] **Najafabadi, M. E., F. Haghighat,** Occupancy-based hvac control systems in buildings: a state-of-the-art review, Build. Environ. 197, 2021, https://doi.org/10.1016/j.buildenv.2021.107810.

[7] **Moradzadeh, A., B. M. Ivatloo, M. Abapour, A. A. Moghaddam, S. S. Roy,** Heating and cooling loads forecasting for residential buildings based on hybrid machine learning applications: a comprehensive review and comparative analysis, *IEEE Access 10*, 2196–2215, 2022, 107810, https://doi.org/10.1109/access.2021.3136091.

[8] **Maddalena, E. T., Y. Lian, C. N. Jones,** Data-driven methods for building control a review and promising future directions, *Control Eng. Pract. 95*, 2020, 104211, https://doi.org/10.1016/j.conengprac.2019.104211.

[9] **Ghahramani, A., P. Galicia, D. Lehrer, Z. Varghese, Z. Wang, Y. Pandit,** Artificial intelligence for efficient thermal comfort systems: requirements, current applications and future directions, *Frontiers in Built Environment 6*, 2020, 6, https://doi.org/10.3389/fbuil.2020.00049.

[10] **Han, M., R. Ross May, X. Zhang, X. Wang, S. Pan, D. Yan, Y. Jin, L. Xu,** A review of reinforcement learning methodologies for controlling occupant comfort in buildings, *Sustain. Cities Soc. 51*, 2019, 101748, https://doi.org/10.1016/j.scs.2019.101748.

[11] **Yao, Y., D. K. Shekhar,** State of the art review on model predictive control (MPC) in Heating Ventilation and Air-conditioning (HVAC) field, *Building and Environment*, *200*, 2021, 107952, https://doi:10.1016/j.buildenv.2021.107952

[12] **Gomariz, M. P., A. L. Gómez, F. C. Cartagena,** Artificial neural networks as artificial intelligence technique for energy saving in refrigeration systems – A review, *Clean Technologies* 5, 2023, 1, pp. 116-136, https://doi.org/10.3390/cleantechnol5010007

[13] **Salehi, H., R. Burgueño,** Emerging artificial intelligence methods in structural engineering, *Engineering Structures*, *171*, 2018, pp. 170-189, https://doi:10.1016/j.engstruct.2018.05.084

[14] **Yuan, X., Y. Pan, J. Yang, W. Wang, Z. Huang,** Study on the application of reinforcement learning in the operation optimization of HVAC system, *Building Simulation 14*, 201, 1, pp. 75–87, 2021, https://doi.org/10.1007/s12273-020-0602-9

[15] **Chen, B., Z. Cai, M. Berges,** Gnu-rl: a practical and scalable reinforcement learning solution for building hvac control using a differentiable MPC policy, *Frontiers in Built Environment 6*, 2020, https://doi.org/10.3389/fbuil.2020.562239

[16] **Solinas, F. M., A. Macii, E. Patti, L. Bottaccioli,** An online reinforcement learning approach for HVAC control, *Expert Systems with Applications*, 238 2024, Part A, 121749, https://doi.org/10.1016/j.eswa.2023.121749.

[17] **Deng, Z., Q. Chen,** Reinforcement learning of occupant behavior model for cross-building transfer learning to various hvac control systems, *Energy and Buildings*, *238*, 2021, 110860, https://doi.org/10.1016/j.enbuild.2021.110860.

[18] **Chen, Y., L. K. Norford, H. W. Samuelson, A. Malkawi,** Optimal control of HVAC and window systems for natural ventilation through reinforcement learning, *Energy and Buildings*, *169*, 2018, pp 195–205, https://doi.org/10.1016/j.enbuild.2018.03.051.

[19] **Nasruddin, Sholahudin, P. Satrio, T. M. I. Mahlia, N. Giannetti, K. Saito, K.,** Optimization of HVAC system energy consumption in a building using artificial neural network and multi-objective genetic algorithm, *Sustainable Energy and Technologies Assessments*, *35*, 2019, pp. 48–57, https://doi.org/10.1016/j.seta.2019.06.002.

[20] **Arranz R. S., A. Gutiérrez,** A long short-term memory artificial neural network to predict daily HVAC consumption in buildings, *Energy and Buildings*, *216*, 2020, 109952, https://doi.org/10.1016/j.enbuild.2020.109952

[21] **Abida, A., P. Richter,** HVAC control in buildings using neural network, *Journal of Building Engineering*, *65*, 2023, 105558, https://doi.org/10.1016/j.jobe.2022.105558

[22] **Ikeda, S., T. Nagai,** A novel optimization method combining metaheuristics and machine learning for daily optimal operations in building energy and storage systems, *Applied Energy*, *289*, 2021, 116716, https://doi.org/10.1016/j.apenergy.2021.116716.

[23] **Wei, T., Y. Wang, Q. Zhu**, Deep reinforcement learning for building HVAC control, Proceedings, 54th ACM/EDAC/IEEE Design Automation Conference (DAC), 2017, Art. No. 22, https://doi.org/10.1145/3061639.3062224

[24] **Gupta, A., Y. Badr, A. Negahban, G. Robin, Qiu,** Energy-efficient heating control for smart buildings with deep reinforcement learning, *Journal of Building Engineering*, *34*, 2021, 101739, https://doi.org/10.1016/j.jobe.2020.101739.

[25] **Nguyen, A. T., D. H. Pham, B. L. Oo, M. Santamouris, Y. Ahn, B. T. H.,** Modelling building HVAC control strategies using a deep reinforcement learning approach, *Energy and Buildings*, *310*, 2023, 114065, https://doi.org/10.1016/j.enbuild.2024.114065.

[26] **Deng, X., Y. Zhang, H. Qi,** Towards optimal hvac control in non-stationary building environments combining active change detection and deep reinforcement learning, *Building and Environment*, *211*, 2022, 108680, https://doi.org/10.1016/ j.buildenv.2021.108680.

[27] **Fard, Z. Q., Z. S. Zomorodian, S. S. Korsavi,** Application of machine learning in thermal comfort studies: A review of methods, performance and challenges, *Energy and Buildings*, *256*, 2022, 111771, https://doi.org/10.1016/j.enbuild.2021.111771.

[28] **Wang, Z., J. Liu, Y. Zhang, H. Yuan, R. Zhang, R. S. Srinivasan,** Practical issues in implementing machine-learning models for building energy efficiency: Moving beyond obstacles, *Renewable and Sustainable Energy Reviews*, *143*, 2021, 110929, https://doi.org/10.1016/j.rser.2021.110929.

[29] **Luo, M., J. J. Xie. Y. Yan, Z. Ke, P. Yu, Z. Wang, J. Zhang,** Comparing machine learning algorithms in predicting thermal sensation using ASHRAE Comfort Database II, *Energy and Buildings*, *210*, 2020, 109776, https://doi.org/10.1016/j.enbuild.2020.109776

[30] **Ngarambe, J., G. Y. Yun, M. Santamouris,** The use of artificial intelligence (AI) methods in the prediction of thermal comfort in buildings: energy implications of AI-based thermal comfort controls, *Energy and Buildings*, *211*, 2020, 109807, https://doi.org/10.1016/j.enbuild.2020.109807

[31] **Zhou, Y., Y. Su, Z. Xu, X. Wang, X. Guan,** A hybrid physics-based/data-driven model for personalized dynamic thermal comfort in ordinary office environment, *Energy and Buildings* 2021, 110790, https://doi.org/10.1016/j.enbuild.2021.110790.

[32] **Chen, Z., Z. O'Neill, J. Wen, O. Pradhan, T. Yang, X. Lu, G. Lin, S. Miyata, S. Lee, C. Shen, R. Chiosa, M. S. Piscitelli, A. Capozzoli, F. Hengel, A. Kührer, M. Pritoni, W. Wei Liu, J. Clauß, Y. Chen, T. Herr,** A review of data-driven fault detection and diagnostics for building HVAC systems, *Applied Energy*, *339*, 2023, 121030, https://doi.org/10.1016/j.apenergy.2023.121030

[33] **Viol, V. M., E. M. Urbano, J. E. T. Rangel, M. D. Prieto, L. Romeral,** Semi-supervised transfer learning methodology for fault detection and diagnosis in air-handling units, *Applied Science*, *12*, 2022, 8837, https:// doi.org/10.3390/app12178837.