

Večkriterijska optimizacija postavitve senzorjev temperature površja na podlagi podatkov LiDAR

Niko Lukač, Niko Uremović, David Jesenko, Marko Bizjak

*Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko,
Koroška cesta 46, 2000, Maribor, Slovenia*

E-pošta: { niko.lukac@um.si, niko.uremovic@um.si, david.jesenko@um.si, m.bizjak@um.si }

Multicriteria optimization of surface temperature sensors placement based on LiDAR data

This paper presents a multicriteria optimization method for placing surface temperature sensors based on LiDAR data. A classified LiDAR point cloud is first transformed into a 2.5D grid, enabling optimization of sensor placement over the grid based on three proposed criteria: inter-sensor distance, alignment with average Sky View Factor (SVF), and sensitivity to Land Surface Temperature (LST) variability. Moreover, experiments were performed for an urban area using NSGA-II, NSGA-III, and SPEA2 algorithms. NSGA-II provided the best balance of convergence and solution diversity, particularly for smaller sensor networks. Finally, the experiments confirmed that the proposed method presents a viable solution for optimal surface temperature sensors placement in complex urban environments.

1 Uvod

V zadnjem obdobju smo priča hitremu razvoju mikrosenzorske tehnologije in senzorskih omrežij, ki predstavljajo enega ključnih gradnikov sodobnih pametnih mest [1]. Mikrosenzorji omogočajo neprekinjeno spremljanje okoljskih parametrov z visoko časovno in v primeru množične namestitve tudi prostorsko ločljivostjo. Množično nameščanje v obliki senzorskih omrežij omogočajo majhnost, nizka poraba energije in podpora brezžične komunikacije mikrosenzorjev [2].

Senzorska omrežja, sestavljena iz množice prostorsko razporejenih mikrosenzorjev, tvorijo temelj za razvoj digitalnih dvojčkov mest [3], kjer se z integracijo senzorskih podatkov, geoinformacijskih sistemov in okoljskih simulacij [4, 5] ustvarjajo digitalne kopije mest, ki omogočajo boljše upravljanje z energijo, mobilnostjo, okoljskimi viri ter odzivanje na podnebne spremembe. V okviru digitalnih dvojčkov so podatki o temperaturi površja (angl. Land Surface Temperature, LST) ključnega pomena, saj omogočajo zaznavanje urbanih toplotnih otokov, in posledično načrtovanje ukrepov za zmanjševanje lokalnega segrevanja.

V zadnjih letih je povečana dostopnost LiDAR (angl. Light Detection And Ranging) podatkov še dodatno

izboljšala možnosti za izboljšanje zmogljivosti senzorskih omrežij, saj omogoča pridobivanje podrobnih tridimenzionalnih informacij o površju, kar je ključno za optimalno umeščanje senzorjev [6]. V primerjavi s 3D-podatki, pridobljenimi s satelitskimi posnetki, ima LiDAR višjo ločljivost [7]. LiDAR podatki se običajno zajemajo z zračnimi platformami, kot so brezpilotna letala (droni) ali letala, ki razdaljo do objektov na površju izračunajo na podlagi pretečenega časa od oddaje do vrnitve odbitega laserskega pulza. Rezultat tovrstnega skeniranja je oblak točk, ki ga uporabljamo v tem delu kot osnovo za predstavitev okolice, v kateri iščemo optimalno postavitev senzorjev (angl. Optimal Sensor Placement, OSP), ki predstavlja eno ključnih nalog pri zasnovi in uvedbi naprednih senzorskih sistemov.

OSP vključuje strateško umeščanje senzorjev z namenom maksimiranja njihove učinkovitosti pri zbiranju podatkov, s čimer se zagotavlja celovita pokritost in natančno spremljanje izbranega okolja ali objekta [8, 9, 10]. Osrednji cilj OSP je doseči čim višjo kakovost podatkov ob hkratni uporabi čim manjšega števila senzorjev, kar omogoča optimizacijo delovanja sistema in zmanjšanje stroškov [11]. Tradicionalno je bila pri tem pogosto uporabljena enokriterijska optimizacija, ki se osredotoča na en sam cilj [12]. Vendar pa kompleksna urbana okolja zahtevajo bolj celovite pristope, ki upoštevajo tudi prostorske značilnosti terena v obliki digitalnega modela terena [13] ali podatkov LiDAR [14, 15]. Liu in Ma [13] sta razvila metodologijo za ocenjevanje pokritosti brezžičnih senzorskih omrežij na valovitih terenih z namenom maksimiranja pričakovane pokritosti območja. Oroza in soavtorji [14] so razvili Bayesovski pristop za optimizacijo topologije brezžičnih senzorskih omrežij v zahtevnem terenu predstavljenem s podatki LiDAR, s ciljem maksimiranja verjetnosti uspešnega prenosa podatkov.

Pogosto naletimo na kompleksnejše sisteme, kjer je potrebno med seboj uravnotežiti več ciljev, kar izvajamo z večkriterijsko optimizacijo. Namesto ene same optimalne rešitve iščemo niz t.i. Pareto optimalnih rešitev, kjer izboljšava enega kriterija lahko pomeni poslabšanje drugega. Ta niz rešitev tvori Pareto fronto, ki prikazuje najboljše možne kompromise med cilji

[16, 17].

Domingo-Pérez in soavtorji [16] so uporabili evolucijsko večkriterijsko optimizacijo za določanje optimalne postavitve senzorjev za lokalizacijo na osnovi razlik v razdaljah. Wang je s soavtorji [18] predstavil metodo za večkriterijsko optimizacijo postavitve senzorjev za mrežo merilnih postaj za padavine, pri čemer so avtorji hkrati maksimirali doseg in minimalizirali stroške nameščanja senzorjev. Yang in Xia [17] sta predstavila pristop za robustno večkriterijsko optimizacijo postavitve senzorjev z upoštevanjem negotovosti struktur prek intervalne analize in Pareto fronte.

Glavni prispevek članka je integracija podatkov LiDAR in večkriterijske optimizacije za določitev optimalne postavitve senzorjev temperature površja v urbanih okoljih. Klasificiran oblak točk pretvorimo v 2.5D mrežo, ki zajema topografijo in rabo prostora, kar omogoča natančno prostorsko analizo. V določenih primerih lahko imamo pomanjkljive podatke LiDAR (npr. zaradi pojava večkratne refleksije laserskih žarkov), kar povzroča prazne celice, ki jih nato lahko enostavneje zapolnimo z interpolacijsko metodo kot npr. IDW (angl. Inverse Distance Weighting). 2.5D mreža nam tudi omogoča določanje enake ločljivosti čez celotni prostor, kjer lahko dosežemo kompromis med hitrostjo (nižja ločljivost) in natančnostjo (višja ločljivost). To je predvsem uporabno, kadar imamo na vходу zelo gost oblak točk LiDAR (npr. pod 1 m), kjer bi izračuni neposredno nad točkami bili računsko zahtevnejši. Na tej osnovi v naslednjem poglavju definiramo tri optimizacijske kriterije: povprečno minimalno razdaljo med senzorji, povprečno odstopanje SVF glede na celotno območje ter standardni odklon simulirane LST. Tak pristop omogoča iskanje kompromisnih rešitev z uporabo optimizacijskih algoritmov, kjer posamezne postavitve uravnotežijo odstopanja med kriteriji.

Članek je razdeljen na štiri poglavja. V naslednjem poglavju predstavimo metodologijo optimizacije postavitve, nato pa opišemo rezultate testiranja metodologije s tremi različnimi optimizacijskimi algoritmi. V četrtem poglavju podamo zaključke in predloge za prihodnje delo.

2 Metodologija

V okviru dane metode uporabimo podatke LiDAR, kjer klasificiran 3D oblak točk [19] pretvorimo v 2.5-dimenzionalno mrežo istega obsega G , kjer za vsako celico $c_i \in G$ določimo višino $c_{i,z}$ kot višino maksimalne LiDAR točke v celici. Dana celica prav tako prejme klasifikacijski razred $c_{i,c}$ od maksimalne točke.

Pred zagonom večkriterijske optimizacije najprej definiramo omejitve optimizacije optimizacijskega prostora, tako da se upošteva le $T \in G$, ki vsebuje celice površij, kamor želimo namestiti N senzorjev S . Nato definiramo naslednje optimizacijske kriterije, ki jih

želimo maksimizirati:

$$\text{mindist}(S) = \sum_i^N \frac{d_i^{MIN}}{N}, \quad (1)$$

$$\text{SVF}\Delta(S) = 1 - \left| \sum_i^N \frac{\text{SVF}_i}{N} - \overline{\text{SVF}} \right|, \quad (2)$$

$$\text{LST_STD}\Delta(S) = \sum_i^N \frac{\sigma_i^{LST}}{N}, \quad (3)$$

kjer prvi kriterij $\text{mindist}(S)$ predstavlja povprečno minimalno evklidsko razdaljo d_i^{MIN} od i -tega senzorja do svojega najbližjega. S tem omogočimo, da so senzorji tem bolj oddaljeni drug od drugega in strmimo k uniformni porazdelitvi. Tako dosežemo večjo pokritost celotnega področja T .


Drugi kriterij je $\text{SVF}\Delta(S)$, ki predstavlja povprečno razliko med faktorjem vidnega neba (angl. Sky View Factor, SVF) na lokaciji senzorjev in povprečnim $\overline{\text{SVF}}$ celotnega področja T . SVF je definiran z brezdimenzionalno mero, ki kvantificira, kolikšen del neba je viden iz dane celice. V primeru $\text{SVF}=1$ je celotna ploskev neba vidna, v primeru $\text{SVF}=0$ pa imamo popolno zastrtost dane lokacije. SVF izračunamo z uporabo algoritma metanja žarkov pred zagonom optimizacije. SVF za vsako celico izračunamo z metanjem žarkov v prostor ploskve $360^\circ \times 90^\circ$ s sferično ločljivostjo na celico $h_{res} \times v_{res}$, pri čemer θ in ϕ predstavljata azimutni in višinski kot. SVF je tako definiran kot [15]:

$$\text{SVF} = \frac{1}{\pi} \int_0^{2\pi} \int_0^{\frac{\pi}{2}} V(\theta, \phi) \sin \phi d\phi d\theta, \quad (4)$$

kjer $V(\theta, \phi)$ predstavlja funkcijo vidljivosti v smeri žarka. Tako z drugim kriterijem želimo postavitev senzorjev zajeti čimbolj povprečno vidnost okolice (lahko bi definirali kot kontekst vidljivosti) za dano področje. Senzorji s povprečnim SVF-jem kot celotno območje zagotavljajo reprezentativne meritve, zmanjšujejo pristranskost pri modeliranju mikroklimatskih pogojev v različnih urbanih morfologijah ter sledijo mednarodnim smernicam urbanega klimatološkega vzorčenja pri t.i. urbanih kanjonih [20].

Tretji kriterij je definiran kot $\text{LST_STD}\Delta(S)$, ki predstavlja povprečni standardni odklon simulirane temperature površja σ_i^{LST} na lokaciji i – tega senzorja. σ_i^{LST} izračunamo kot standardni odklon vrednosti simuliranega LST za 4 ekstremne dneve v letu, to so poletni in zimski solsticij ter pomladni in jesenski ekvinokcij. Simulacija LST je področje izven danega članka, temelji pa na avtorjevih predhodnih delih [4, 19]. V splošnem izračunamo LST, definiran kot T_s z numeričnim reševanjem enačbe energijske bilance na površju zemlje za dani časovni trenutek:

$$(1 - \alpha)I = \varepsilon(\sigma T_s^4 - L) + h_c(T_s - T_a) + C, \quad (5)$$



Slika 1: Vhodni podatki: (a) 2.5D mreža G nad podatki LiDAR, (b) izračun SVF-ja, (c) označeno območje T , ter (c) standardni odklon simuliranih LST-jev.

kjer I predstavlja prejeto sončno obsevanje, α albedo (odbojnost) površja, ε emisivnost površja, L prejeto dolgovalovno (termično) sevanje iz okolice, T_a ambientalna temperatura zraka nad površjem, h_c konvekcijski koeficient toplote, ter C kondukcijski tok. Kriterij omogoča robustnejšo usmerjanje parametrov energijske bilance v simulaciji, saj je izračun za temperaturno ekstremna površja najbolj zahtevnejši in nagnjen k napakam. Prav tako dani kriterij omogoča večjo občutljivost na merjenje potencialnih učinkov naknadnih podnebnih in urbanističnih intervencij, kjer se spremembe rabe tal, albeda ali senčenja najhitreje odrazijo v površinski temperaturi.

Ker prvi kriterij zahteva maksimalno medsebojno oddaljenost senzorjev (da minimiziramo prostorsko redundanco), drugi zahteva, da imajo ti isti senzori SVF čim bližji povprečni vrednosti celotnega območja T (kar senzori potiska v morfološko tipične dele, pogosto med seboj bližje), tretji pa jih usmerja na lokacije z največjimi letnimi temperaturnimi nihanji (ki so navadno prostorsko skoncentrirane in imajo ekstremne SVF-je), vsaka izboljšava enega kriterija praviloma poslabša vsaj enega od preostalih dveh; zato globalnega maksimuma, ki bi hkrati optimiziral vse tri funkcije, nad realno okolico ni, in je smiselno iskati celoten Pareto nabor kompromisnih rešitev. V naslednjem poglavju predstavimo nabor dobljenih Pareto rešitev.

3 Rezultati


Večkriterijsko optimizacijo postavitve senzorjev z definiranimi kriteriji smo testirali nad podatki LiDAR lokacije zgradb Fakultete za elektrotehniko, računalništvo in informatiko, Univerza v Mariboru. Vhodni podatki so prikazani na sliki 1, kjer smo najprej zgradili 2.5D klasificirano mrežo (slika 1a) ter izračunali SVF (slika 1b). Nato smo določili območje T (slika 1c) in simulirali LST za 4 ekstremne dneve ter izračunali standardni odklon izračunanih temperatur površij (slika 1d). Simulacija LST je zahtevala dodatne vhodne podatke za dane dni, in sicer direktno in difuzno horizontalno obsevanje kot tudi ambientalno temperaturo zraka, kar smo pridobili iz bližnje meteorološke postaje ARSO pri Vrbanškem platoju, Maribor.

Za izvedbo optimizacije smo uporabili tri znane algoritme, in sicer NSGA-II [21], NSGA-III [22] in SPEA2 [23]. Pri vseh treh smo definirali število generacij oz. iteracij na 5000, ter velikost populacije enako 100, pri čemer je bilo število ovrednotenj kriterijske funkcije enako 5000×100 . Vse tri algoritme smo 5-krat pognali in izračunali metriki povprečnega volumna hiperkocke Pareto rešitev [23] in povprečno razpršenost Pareto rešitev [23], za tri scenarije pri različnih številih senzorjev ($N = 5$, $N = 15$ in $N = 30$). Rezultati so prikazani v tabeli 1. Pred izračunom obeh metrik smo normalizirali prvi kriterij z maksimalno možno razdaljo dveh senzorjev na danem območju. Drugi kriterij je že normaliziran, tretjega pa smo normalizirali z min-max standardnega odklona LST. Hipervolumen H meri, kolikšno prostornino v prostoru rešitev zavzame unija dominiranih točk Pareto fronte. Višji H pomeni, da fronta hkrati sega bližje idealnim vrednostim vseh kriterijev in bolje zapolni kompromisni prostor (v našem primeru so vsi trije normalizirani kriteriji enaki 1). Razpršenost P opisuje enakomernost razporeditve točk po Pareto fronti. Nižja vrednost nakazuje, da so rešitve homogeno pokrile celotno fronto brez "lukenj" ali koncentracije in tako nudijo uporabniku neprekinjen nabor kompromisov. Bolj nazorni prikaz vseh Pareto front je viden na sliki 2. Primer postavitve senzorjev za eno izbrano rešitev na Pareto fronti algoritma NSGA-II je prikazan na sliki 3.


Tabela 1: Rezultat izračunanega hipervolumna Pareto prostora H in razpršenost P Pareto rešitev S pri treh optimizacijskih algoritmi za tri scenarije postavitve senzorjev.

N	Algoritem	$H_{\min}$	$H_{\max}$	$\bar{H}$	$P_{\min}$	$P_{\max}$	$\bar{P}$
5	NSGA-II	0.445	0.822	0.609	0.638	0.791	0.705
	NSGA-III	0.409	0.718	0.585	0.647	0.725	0.702
	SPEA2	0.463	0.597	0.551	1.016	1.178	1.083
15	NSGA-II	0.504	0.619	0.551	0.581	0.690	0.627
	NSGA-III	0.490	0.592	0.553	0.727	0.870	0.779
	SPEA2	0.435	0.602	0.540	0.714	0.906	0.801
30	NSGA-II	0.412	0.484	0.442	0.576	0.668	0.609
	NSGA-III	0.379	0.532	0.443	0.607	0.885	0.732
	SPEA2	0.354	0.528	0.450	0.563	0.728	0.641

Rezultati kažejo, da je pri majhnem številu senzorjev



Slika 2: Grafični prikaz Pareto front za vse tri izbrane algoritme pri različnih scenarijih števila senzorjev.



Slika 3: Vizualizacija postavitve senzorjev pri eni izmed mnogih rešitev na Pareto fronti pridobljeni z algoritmom NSGA-II.

($N = 5$) NSGA-II dosegel najvišji povprečni hipervolumen ($\bar{H} = 0,609$) in hkrati zelo blizu najnižje povprečne razpršenosti ($\bar{P} = 0,705$), kar pomeni najboljšo kombinacijo konvergence in enakomerne pokritosti fronte. Pri tem NSGA-III sicer dosega skoraj enak hipervolumen, a z nekoliko boljšo razpršenostjo, medtem ko je SPEA2 zaradi najvišjih vrednosti P v povprečju najslabši. Pri srednjem scenariju ($N = 15$) razlike med algoritmi v $\bar{H}$ skoraj izginejo, vendar NSGA-II dosega najnižji P . Pri največ senzorskih lokacijah ($N = 30$) NSGA-III doseže najvišji $H_{\max} = 0,532$ in s tem nakazuje boljšo zmožnost iskanja skrajnih kompromisov, vendar NSGA-II in SPEA2 ponujata bolj homogeno porazdelitev ($\bar{P} = 0,609$ in $0,641$ proti $0,732$). Skupno torej NSGA-II izstopa kot najbolj uravnovešena izbira pri manjših in srednjih senzorskih omrežjih, medtem ko NSGA-III pri večji populaciji senzorjev bolje razširi fronto v smeri optimalnega hipervolumna.

4 Zaključek

Eksperimenti kažejo, da je algoritem NSGA-II pri manjših in srednjih senzorskih omrežjih ($N = 5$ in $N = 15$) dosegel hkrati najvišji povprečni hipervolumen Pareto prostora in blizu najnižje povprečne razpršenosti. S tem je zagotovil najbolj uravnovešeno kompromisno

fronto med tremi nasprotujočimi si kriteriji: prostorsko razpršenostjo senzorjev, reprezentativnostjo SVF in občutljivostjo na temperaturna nihanja LST. Pri večjem številu senzorjev ($N = 30$) se je algoritem NSGA-III izkazal z nekoliko boljšim maksimalnim hipervolumnom, vendar je NSGA-II tudi tam zagotavljal bolj homogeno porazdelitev rešitev, kar potrjuje njegovo splošno robustnost.

Predstavljena metoda ima tudi več omejitev. Ločljivost in klasifikacijska točnost vhodnih podatkov LiDAR neposredno vplivata na natančnost 2.5D mreže in posledično na izračun SVF. Prav tako simulirane vrednosti LST temeljijo na energijskem modelu, ki vključuje številne parametre (albedo, emisivnost, itd.), pri čemer netočnosti ali manjkajoči vhodni podatki lahko povzročijo pristranskost v tretjem kriteriju.

V prihodnje bomo preizkusili še druge večkriterijske evolucijske algoritme. Razviti želimo tudi sistem, ki bo po namestitvi senzorjev samodejno usmerjal energijski model simulacije na podlagi realnih meritev in tako iterativno izboljšal simuliranje LST. Dodatno bomo raziskali uvedbo ekonomskih in logističnih kriterijev (strošek montaže, dostopnost lokacij) ter testirali prenosljivost metode na večje geografsko področje.

Zahvala

Raziskovalno delo je bilo sofinancirano s strani Javne agencije za znanstvenoraziskovalno in inovacijsko dejavnost Republike Slovenije, v okviru temeljnega projekta št. J7-50095 in raziskovalnega programa št. P2-0041. Za podatke LiDAR in meteorološke meritve se zahvaljujemo Agenciji Republike Slovenije za okolje.

Literatura

- [1] C. L. Muller, L. Chapman, C. S. B. Grimmond, D. T. Young, and X. Cai, "Sensors and the city: a review of urban meteorological networks," *Int. J. Climatol.*, vol. 33, no. 7, pp. 1585–1600, 2013.
- [2] M. R. Giordano, C. Malings, S. N. Pandis, A. A. Presto, V. F. McNeill, D. M. Westervelt, M. Beekmann, and R. Subramanian, "From low-cost sensors to high-quality data: A summary of challenges and best practices for effectively calibrating low-cost particulate matter mass sensors," *Journal of Aerosol Science*, vol. 158, p. 105833, 2021.
- [3] T. Wang, V. J. L. Gan, D. Hu, and H. Liu, "Digital twin-enabled built environment sensing and monitoring through semantic enrichment of bim with sensorml," *Automation in Construction*, vol. 144, p. 104625, 2022.
- [4] M. Bizjak, B. Žalik, G. Štumberger, and N. Lukač, "Large-scale estimation of buildings' thermal load using lidar data," *Energy and Buildings*, vol. 231, p. 110626, 2021.
- [5] N. Lukač, D. Mongus, B. Žalik, G. Štumberger, and M. Bizjak, "Novel gpu-accelerated high-resolution solar potential estimation in urban areas by using a modified diffuse irradiance model," *Applied Energy*, vol. 353, p. 122129, 2024.
- [6] T.-H. Kim, G.-H. Jo, H.-S. Yun, K.-S. Yun, and T.-H. Park, "Placement method of multiple lidars for roadside infrastructure in urban environments," *Sensors*, vol. 23, no. 21, p. 8808, 2023.
- [7] D. Kavran, D. Mongus, B. Žalik, and N. Lukač, "Graph neural network-based method of spatiotemporal land cover mapping using satellite imagery," *Sensors*, vol. 23, no. 14, p. 6648, 2023.
- [8] F. Lin and P. Chiu, "A near-optimal sensor placement algorithm to achieve complete coverage-discrimination in sensor networks," *IEEE Communications Letters*, vol. 9, no. 1, pp. 43–45, 2005.
- [9] J. Jiang, J. Wang, H. Wu, C. Lee, C. Chou, L. Wu, and Y. Yang, "A novel sensor placement strategy for an iot-based power grid monitoring system," *IEEE Internet of Things Journal*, vol. 7, no. 8, pp. 7773–7782, 2020.
- [10] S. Kord, T. Taghikhany, A. Madadi, and O. Hosseinbor, "A novel triple-structure coding to use evolutionary algorithms for optimal sensor placement integrated with modal identification," *Structural and Multidisciplinary Optimization*, vol. 67, no. 4, p. 58, 2024.
- [11] H. Hu, Z. Liu, S. Chitlangia, A. Agnihotri, and D. Zhao, "Investigating the impact of multi-lidar placement on object detection for autonomous driving," in *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2022, pp. 2540–2549.
- [12] Z. A. Aghbari, A. M. Khedr, W. Osamy, I. Arif, and D. P. Agrawal, "Routing in wireless sensor networks using optimization techniques: A survey," *Wireless Personal Communications*, vol. 111, no. 4, pp. 2407–2434, 2020.
- [13] L. Liu and H. Ma, "On coverage of wireless sensor networks for rolling terrains," *IEEE Transactions on Parallel and Distributed Systems*, vol. 23, no. 1, pp. 118–125, 2012.
- [14] C. A. Oroza, J. A. Giraldo, M. Parvania, and T. Watteyne, "Wireless-sensor network topology optimization in complex terrain: A bayesian approach," *IEEE Internet of Things Journal*, vol. 8, no. 24, pp. 17 429–17 435, 2021.
- [15] N. Lukač, D. Kavran, M. F. Ovčjak, and M. Bizjak, "Genetic algorithm for optimizing meteorological sensors placement using airborne lidar data," in *Proc. 2024 IEEE 24th International Symposium on Computational Intelligence and Informatics (CINTI)*, 2024, pp. 197–202.
- [16] F. Domingo-Perez, J. L. Lazaro-Galilea, A. Wieser, E. Martin-Gorostiza, D. Salido-Monzu, and À. de la Llana, "Sensor placement determination for range-difference positioning using evolutionary multi-objective optimization," *Expert Systems with Applications*, vol. 47, pp. 95–105, 2016.
- [17] C. Yang and Y. Xia, "Interval pareto front-based multi-objective robust optimization for sensor placement in structural modal identification," *Reliability Engineering and System Safety*, vol. 242, p. 109703, 2024.
- [18] K. Wang, J. Yang, Y. Peng, Q. Wu, and C. Hu, "Multiobjective optimization of sensor placement for precipitation station monitoring network design," *Journal of Hydrologic Engineering*, vol. 25, no. 9, p. 04020039, 2020.
- [19] N. Lukač, D. Mongus, B. Žalik, G. Štumberger, and M. Bizjak, "Novel GPU-accelerated high-resolution solar potential estimation in urban areas by using a modified diffuse irradiance model," *Applied Energy*, vol. 353, p. 122129, Jan. 2024.
- [20] T. R. Oke, *Boundary layer climates*, 2nd ed. London: Methuen, 1987.
- [21] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, Apr. 2002.
- [22] J. Blank, K. Deb, and P. C. Roy, "Investigating the Normalization Procedure of NSGA-III," in *Lecture Notes in Computer Science*. Cham: Springer International Publishing, 2019, pp. 229–240.
- [23] E. Zitzler, M. Laumanns, and L. Thiele, "SPEA2: Improving the strength pareto evolutionary algorithm," ETH Zurich, Tech. Rep., May 2001.