

Karol Łoziński (karol.lozinski@doktorant.pk.edu.pl)

 <https://orcid.org/0009-0001-3724-3722>

Politechnika Krakowska im. Tadeusza Kościuszki, Szkoła Doktorska PK,
Wydział Architektury

Algorytmy genetyczne – zastosowanie w urbanistyce i planowaniu

Genetic algorithms – application in urban design and planning

Streszczenie

Żyjąc w dobie powszechnej cyfryzacji, coraz częściej napotykamy rozwiązania związane ze sztuczną inteligencją, uczeniem maszynowym czy algorytmami genetycznymi. Technologie te są w stanie znacząco przyspieszać wiele procesów, zwłaszcza bazujących na dużej ilości danych. Ten artykuł skupia się na wykorzystaniu algorytmów genetycznych w pracy urbanistów i planistów. Omówiono tu zasady działania algorytmów, ich przyszłe możliwości oraz wątpliwości dotyczące ich wykorzystania.

Słowa kluczowe: urbanistyka, planowanie przestrzenne, algorytmy genetyczne, uczenie maszynowe

Abstract

Living in the era of universal digitalization, we increasingly encounter solutions related to artificial intelligence, machine learning or genetic algorithms. These technologies are able to significantly accelerate many processes, especially those based on large amounts of data. This article focuses on the – genetic algorithms – in the work of urban planners and planners. The principles of operation, their example use so far, future possibilities and doubts regarding their use are discussed.

Keywords: urban planning, spatial planning, genetic algorithms, machine learning

1. PODSTAWY I HISTORIA

Algorytmy genetyczne to algorytmy metaheurystyczne (algorytmy ogólne stosowane do rozwiązywania problemów obliczeniowych; przeważnie optymalizacyjny), których zasada działania jest inspirowana procesami selekcji naturalnej. Algorytmy te należą to szerszej grupy algorytmów ewolucyjnych (Petrovski, 2017).

Algorytmy genetyczne wykorzystywane są jako narzędzia optymalizacyjne stosowane do rozwiązywania skomplikowanych problemów, korzystając z operatorów inspirowanych naturą, takich jak mutacja, krzyżówka czy selekcja (Melanie, 1998). W takich algorytmach populacja (grupa) proponowanych rozwiązań (zwanych też indywiduami, tworam lub fenotypami) w konkretnym problemie optymalizacyjnym jest stopniowo ewoluowana w celu otrzymania jak najlepszego rozwiązania. Każde proponowane rozwiązanie składa się z zestawu cech (zwanych chromosomami lub genotypami), które mogą być mutowane lub zmienione. Zwykle rozwiązania przedstawione są jako binarny ciąg zer i jedynek, ale możliwe są inne reprezentacje¹. Dane zawarte w owych chromosomach lub genotypach nazywamy genami.

Proces ewolucyjny zaczyna się z populacją losowo wygenerowanych fenotypów i jest to proces iteracyjny, z populacją w każdej iteracji zwanej pokoleniem. W każdym pokoleniu oceniana jest trafność lub inaczej zdolność dostosowania się – wybierany jest fenotyp najbliższy w procesie ewolucyjnym do zadanego celu z całego pokolenia. W niektórych algorytmach metodą stochastyczną może zostać wybrana określona wielkościowo grupa najbardziej przystosowanych fenotypów. Wówczas genotyp każdego z osobników jest losowy mutowany. Po mutacji nowy genotyp jest ziarnem zaczynającym nowe pokolenie, a proces się powtarza. Praca algorytmu kończy się po osiągnięciu satysfakcjonująco bliskiego celowi wyniku, w wyniku osiągnięcia pierwotnie zaplanowanej liczby pokoleń lub po upływie zadanego czasu.

Typowy algorytm genetyczny wymaga:

- reprezentacji genotypowej mieszczącej się w zakresie rozwiązań,
- funkcji trafności, celu (ang. *fitness function*), do którego dąży rozwiązanie (Whitley, 1994).

2. ZASADY DZIAŁANIA

Wielkość populacji zależy od natury problemu, ale z reguły zawiera od kilkuset do kilku tysięcy możliwych rozwiązań.

Z każdego zakończonego pokolenia wybierane są fenotypy o wartościach charakterystycznych najbliższych zadanemu celowi (ang. *highest fitness value*). Sposób wyboru tych fenotypów może się różnić między algorytmami (od czysto stochastycznych [losowych]

¹ Inne możliwe interpretacje to np. grafy, wykresy, modele itd. (Whitley, 1994).

przez prostą barierę wartości minimalnych, skończywszy na wyszukanych średnich ważonych dla każdego fenotypu).

Do zobrazowania funkcji celu przytoczyć można problem plecaka. Wyobraźmy sobie, że dany mamy plecak o skończonym, zadanym udźwigu, a także skończoną liczbę elementów o różnej wartości i zróżnicowanej wadze. Pytanie brzmi: w jaki sposób dobrać ze sobą konkretne składowe, aby uzyskać największą wartość plecaka, jednocześnie mieszcząc się w dopuszczalnej nośności? Ten cel będzie naszą funkcją celową, kolejne elementy o podanej wartości i masie – fenotypami, a owe ceny i masy – genotypami lub chromosomami. Algorytm będzie w każdym pokoleniu próbował setek układów i z każdego pokolenia wybierał kilka, których wartość w dopuszczalnej pakowności jest największa z danego pokolenia. Następnie taki fenotyp będzie odpowiednio zmodyfikowany losową mutacją lub krzyżówką z innym sukcesywnym fenotypem i na ich podstawie rozpocznie się nowe pokolenie, zataczając kolejne koło w iteracyjnym procesie poszukiwania rozwiązania (Martello, Toth, 1990).

Dla każdego nowego fenotypu potrzebnych jest dwoje „rodziców”, a więc sukcesywne fenotypy z poprzedniego pokolenia. Nowy fenotyp może być efektem mutacji lub krzyżówki, jednak zawsze zawiera w sobie elementy „rodziców”.

Warto zaznaczyć, że tworzenie nowego fenotypu jest wynikiem czystej inspiracji światem biologii. Niektórzy badacze twierdzą, że tworzenie nowych fenotypów z większej liczby „rodziców” tworzy silniejsze chromosomy (Eiben i in., 1994).

Rezultatem tego procesu jest całe pokolenie bliższe funkcji celu, ponieważ większość fenotypów opiera się na sukcesywnych fenotypach poprzedniej generacji. Niemniej jednak do nowego pokolenia trafiają też mniej udane fenotypy. Ich celem jest zapewnienie większej mieszanki genotypowej w kolejnych pokoleniach.

Oprócz powyższych metod dywersyfikacji kolejnych pokoleń (mutacja/krzyżówka) inne metody heurystyczne mogą zostać wykorzystane w celu przyspieszenia kalkulacji bądź zwiększenia ich dokładności.

Zakończenie procesu najczęściej jest owocem jednego z poniższych wydarzeń:

- odnaleziono rozwiązanie, spełniające zadane kryteria minimalne,
- osiągnięto z góry ustaloną liczbę pokoleń,
- przewidziany budżet (czasu/pieniędzy) został osiągnięty,
- najwyżżej oceniane rozwiązanie zostało osiągnięte lub osiągnięto wypłaszczenie w rozwiązaniach, gdzie kolejne pokolenia nie produkują rozwiązań lepszych niż poprzednie,
- nastąpiła ręczna inspekcja,
- kilka z powyższych,
- ograniczenia algorytmów genetycznych (Safe i in., 2004).

3. MOŻLIWOŚCI I OGRANICZENIA

Wielokrotne reewaluowanie funkcji celowej przy złożonych przestrzennych, multimodalnych problemach, takich jak ocena wytrzymałości przestrzennych elementów konstrukcyjnych, jest obecnie niezwykle czasochłonne, gdyż jedna reewaluacja (pokolenie) trwa niejednokrotnie wiele godzin lub cały dzień. Pomocne wtedy są siostrzane metody, takie jak ocena zbliżonej celności. Połączenie tych modeli jest jedną z nadziei na zastosowanie algorytmów genetycznych w codziennym życiu.

Algorytmy genetyczne mają problemy ze skalowaniem wraz z rozwojem poziomu skomplikowania problemu, co z reguły skutkuje drastycznym zwiększeniem pola poszukiwań (liczby możliwych rozwiązań). Każda dodatkowa zmienna, z zasady, zwiększa wykładniczo taką liczbę, a to z kolei wpływa na moce obliczeniowe i potrzebny na wykonanie obliczeń czas (Ruthen, 2010).

Końcowe rozwiązanie jest najlepsze jedynie w odniesieniu do zaproponowanych fenotypów. Nie daje to gwarancji ogólnego, najlepszego rozwiązania w rzeczywistym podejściu.

W przypadku wielu zadanych problemów algorytmy genetyczne mają tendencję do skłaniania się ku lokalnemu optimum zamiast ku globalnemu. To oznacza, że algorytm „nie wie”, jak poświęcić tymczasowe sukcesy kolejnych pokoleń w celu otrzymania długofalowych zysków. Problem ten jest mocno uzależniony od natury problemu – w wypadku niektórych skłonność ta w ogóle nie występuje, inne zaś wymagają dodatkowych rozwiązań, zmniejszających tę skłonność (Taherdangkoo i in., 2013). Jednymi z takich rozwiązań jest modyfikacja funkcji celowej, zwiększenie liczby mutacji lub wykorzystanie technik utrzymujących chromosomowe zróżnicowanie pokolenia, niemniej jednak *Teoria Braku Darmowego Lunchu* (Wolpert, Macready, 1997) (ogólna teoria braku „lepszego” AG [algorytmu genetycznego]; wszystkie dostępne narzędzia uczenia maszynowego działają na zbliżonym poziomie) zdaje się zaprzeczać istnieniu jakiegokolwiek ogólnego rozwiązania. To w konsekwencji prowadzi do problemu wynikającego z natury samych AG. Algorytmy te nie gwarantują rozwiązania. Jeżeli nie zdefiniujemy granicy, powyżej (lub poniżej) której otrzymany wynik jest dla nas zadowalający, lub nie wyłączymy ręcznie symulacji, obliczenia mogą trwać w nieskończoność (Ruthen, 2010).

4. ZASTOSOWANIE W NAUCE

Algorytmy genetyczne znalazły szerokie zastosowanie w nauce. Jako przykład można podać ich wykorzystanie do zaprojektowania luster oraz silnika indywidualnych elektrowni CSP²

² Concentrated Solar Power – skumulowana moc promieniowania słonecznego; elektrownie CSP wykorzystują zwierciadła kierujące promienie słońca w jeden punkt w celu wytworzenia energii.

(Gross, 2003). Innym bardzo znanym przykładem zastosowania algorytmu genetycznego jest antena radiowa, zaprojektowana w 2006 r. przez NASA na potrzeby misji Space Technology 5 (ST5). Antena została wygenerowana przez algorytm genetyczny, mający na celu maksymalizację sygnału radiowego przy możliwie prostej konstrukcji (Hornby i in., 2006). Algorytmy znajdują zastosowania też w dziedzinie awiacji, na przykład przy optymalizacji aerodynamicznej podczas hipersonicznego wejścia w atmosferę (Evans, Walton, 2017) czy też w mniej oczywistych rozwiązaniach, bardzo szeroko stosowanych w dzisiejszym świecie, jak np. rozpoznawanie kształtów poprzez analizę wzorów punktowych, co jest przydatne np. w analizie gwiazd na zdjęciach galaktyk (Ogawa, 1986) czy w analizie danych przestrzennych (Laurini, 1998).



Il. 1. Antena radiowa, której kształt został wygenerowany przez algorytm genetyczny (NASA, 2006)

5. ZASTOSOWANIE W URBANISTYCE

Urbanistyka i planowanie przestrzenne to dziedziny, które ze swojej natury świetnie wpisują się w możliwości wykorzystania algorytmów genetycznych. Planowanie przestrzeni miejskiej często polega na rozwiązywaniu problemów poprzez znalezienie złotego środka na podstawie szeregu zmiennych wsadowych, gdzie mnogość możliwych rozwiązań do rozważenia jest niemożliwa do indywidualnej analizy.

Wszechstronność narzędzia, jakim są algorytmy genetyczne w urbanistyce i planowaniu, jest najlepiej widoczna w ogromnej liczbie przypadków i badań, na jakie można natrafić w dostępnej literaturze. Wskazać należy zarówno zastosowania czysto teoretyczne, proponujące nowe metody pracy lub analizy oderwane od rzeczywistości, jak również badania oparte na realnych tkankach miejskich, znaleźć można również rozwiązania dotyczące nowych metod projektowania, jak i analizy i propozycje poprawy istniejących przykładów.

Algorytmy genetyczne, z uwagi na możliwości radzenia sobie z dużą ilością danych, świetnie radzą sobie w analizie i generatywnym tworzeniu modeli planistycznych, np. maksymalizujących możliwości wykorzystania energii słonecznej.


Jednym z złożonych problemów urbanistycznych jest takie planowanie tkanki, aby zachować komfort termiczny dla mieszkańców. Zmierzenie i określenie komfortu termicznego jest problemem samym w sobie, jako że nie sposób określić go pojedynczym wskaźnikiem takim jak temperatura powietrza. Na komfort termiczny wpływa znacznie więcej zmiennych, gdzie oprócz temperatury wymienia się wilgotność, prędkość wiatru czy stopień aktywności fizycznej. Stąd do określania poziomu komfortu termicznego wykorzystuje się wskaźnik UTCI³, łączący w sobie wymienione zmienne oraz wiele innych, zapewniający miarodajność i powtarzalność mierzonych wartości (Błażejczyk i in., 2013). Dysponując taką miarą, możliwe jest rozpatrywanie sposobów projektowania przestrzeni miejskiej z naciskiem na uzyskanie jak najlepszych wartości UTCI. Mając jednak na uwadze, że sam w sobie współczynnik łączy w sobie wiele zmiennych, do których dochodzi szereg dodatkowych, wynikających z właściwości przestrzennych projektowanego obszaru, należy zaznaczyć, iż jest to wielowątkowy problem, w rozwiązaniu którego pomoc mogą właśnie algorytmy genetyczne.

Badania w zakresie możliwości wykorzystania wskaźnika UTCI jako celu optymalizacyjnego w planowaniu i urbanistyce przeprowadzili w 2015 r. Bajšanski i in., opracowując analizę UTCI dla ulic w miejscowości Nowy Sad w Serbii. Uzyskali wówczas możliwe rozwiązania urbanistyczno-architektoniczne, mające na celu poprawę komfortu termicznego dla mieszkańców. Jako jeden z elementów mających wpływ na komfort termiczny mieszkańców podali wysokość budynków, która po zwiększeniu się obniży wskaźnik UTCI w poziomie pieszych (Bajšanski i in., 2015).


Problematyka UTCI w ujęciu urbanistycznym została też poruszona przez Xu i in. w 2019 r., kiedy przeprowadzili oni teoretyczną analizę generatywnie tworzonych kwartałów przy założeniu zróżnicowanych morfologii w celu oszacowania najlepszego wariantu morfologicznego z punktu widzenia komfortu termicznego (Xu i in., 2019).

Współcześnie coraz większy nacisk kładziony jest na ekologiczne formy budownictwa, maksymalizujące wykorzystanie odnawialnych źródeł energii, w tym m.in. fotowoltaikę. Temat projektowania urbanistycznego i planowania całych kwartałów z myślą o maksymalizacji

³ Universal Thermal Climate Index – Uniwersalny Wskaźnik Temperatury; wskaźnik oparty na wielu składowych, realistycznie oddający temperaturę odczuwaną przez człowieka.



II. 2. Schemat przyjętego procesu optymalizacji modelu (Xu i in., 2019)




II. 3. Wyniki przeprowadzonych analiz UTCI na wygenerowanych kwartałach (Xu i in., 2019)


zysków słonecznych został szeroko opracowany w literaturze (Fink, Koenig, 2019; Saratsis i in., 2017; Shi i in., 2021).

W 2020 r. Shi z zespołem opracowali narzędzie w postaci generatora kwartałów zabudowy (oryg. Urban Block Generator), który przy współpracy z algorytmami genetycznymi wspartymi danymi pogodowymi był w stanie zaproponować nowy układ zabudowy, maksymalizujący potencjał fotowoltaiczny. Istotne było również wzięcie pod uwagę kosztów takiej inwestycji oraz skala przedsięwzięcia (Shi i in., 2021).

Przykładem wykorzystania algorytmów genetycznych w procesie analizy i projektowej interwencji w istniejącej tkance jest badanie Diego Navarro-Mateu i in. z 2018 r., w którym badacze przeanalizowali barceloński Superblok i spróbowali wskazać możliwości adaptacji tkanki w taki sposób, aby przy zachowaniu bieżącej gęstości wrócić do pierwotnych założeń




II. 4. Evolucja kwartału bloków Cerdy na przestrzeni lat (Navarro-Mateu i in., 2018)




II. 5. Render z analizą zacielenia zawierający 100 Superbloków, będących wynikiem pracy algorytmu w przytoczonym badaniu (Navarro-Mateu i in., 2018)

Ildefonsa Cerdy (uważanego za ojca urbanistyki epoki modernizmu, autora znanego planu przestrzennego fragmentu Barcelony, dzielnicy Eixample), tj. bardziej otwartych kwartałów niż istniejące obecnie. Dzięki wykorzystaniu projektowania parametrycznego oraz algorytmów genetycznych, byli w stanie przygotować 100 propozycji superbloków, spełniających zadane kryterium, zamiast pojedynczego optymalnego, którego przygotowanie i tak byłoby ogromnie czasochłonne (Navarro-Mateu i in., 2018).

W ramach wielu zastosowań algorytmów genetycznych oraz narzędzi do generatywnego tworzenia kwartałów zabudowy znaleźć można przypadki wykorzystania tych narzędzi do zaprojektowania przestrzeni przyjaznej pieszym. Pracę na ten temat przygotował w 2012 r. Tarek Rakha. W badaniach jako przykład zastosowania swoich metod badawczych wygenerował on kwartał na modelu realistycznie oddanej rzeźby terenu. Po rozpatrzeniu przez algorytm setek możliwych układów wskazany został ten optymalny dla zastanej sytuacji przestrzennej (Rakha, 2012).




Il. 6. Model terenu z naniesionymi siatkami ulic (Rakha, 2012)




Il. 7. Ilustracja zoptymalizowanej alokacji wykorzystania terenu oraz punktacja dostępności pieszej (Rakha, 2012)

Badanie w zakresie dostępności pieszej przeprowadziła również Judyta Cichocka w 2015 r., opierając się na istniejącej realnej tkance. Jej celem było wykorzystanie narzędzi generatywnych i algorytmów genetycznych oraz algorytmu Dijkstry do optymalizacji



Il. 8. Graficzne przedstawienie dostępności pieszej przed optymalizacją (Cichocka, Łuczak, 2015)

obszaru zabudowy pod kątem dostępności. Jej praca podniosła punktację dostępności pieszej z pierwotnych 60,02 na 85,42⁴, co jest świetnym wynikiem (Cichocka, Łuczak, 2015).




Il. 9. Graficzne przedstawienie dostępności pieszej po optymalizacji (Cichocka, Łuczak, 2015)

W 2020 r. opublikowano pracę dotyczącą planowania algorytmicznego wykorzystanego do projektowania obozów dla uchodźców. Badacze wyszli z założenia, że jakość takich obozów ma duży wpływ na jakość życia osób się tam znajdujących, a rzeczy takie jak obiekty


⁴ Mowa o narzędziu Walk Score, stworzonym przez spółkę Walk Score. Narzędzie to służy do analizy dostępności pieszej (ang. *walkability*) w przestrzeni miejskiej. WalkScore to rodzaj zautomatyzowanego modelu wydajności skupionej na wydajności lokalizacji. Wynik ten może być przypisany do konkretnego adresu czy całego regionu. Skala prezentowana jest w przedziale od 0 do 100, gdzie wynik 100 oznacza *maksymalnie dostępny pieszo*. W ramach analizy brane pod uwagę są nie tylko dystans czy liczba połączeń pieszych, ale też liczba usług na tej drodze, która może generować taki ruch (WalkScore, b.d.). Wyższe wyniki tego wskaźnika zostały skorelowane z wyższymi wartościami nieruchomości (Goldstein, 2016). Warto zaznaczyć, że wskaźnik był już krytykowany za bardzo ogólną metodologię obliczania, np. z uwagi na pomijanie takich kwestii jak brak chodnika, liczbę przejść przez ulicę, poziom bezpieczeństwa czy jakość usług (np. sklep spożywczy a sklep monopolowy) (Vanderbilt, 2012).

powstają często w pośpiechu, nie pozostawiając wiele czasu na planowanie. Zaproponowano wykorzystanie algorytmów genetycznych do szybkiej analizy dostępnych danych przestrzennych, aby zoptymalizować i przyspieszyć proces planistyczny dla tego typu obiektów (Andriasyan i in., 2020).

Algorytmy i narzędzia generatywne wykorzystywane są we wspomnianej pracy w szeregu działań. Począwszy od prostego wydzielenia parceli spośród dostępnego terenu, przez zasięg




II. 10. Podział dostępnego terenu na parcele (Andriasyan i in., 2020)



II. 11. Możliwe kierunki propagacji pożaru (Andriasyan i in., 2020)

pieszy miejsc udzielania pomocy, przez analizy możliwych kierunków rozprzestrzeniania się ognia, dystansu ewakuacji, skończywszy na dostępie do sanitariatów.




Il. 12. Analiza dostępu do sanitariatów dla opracowywanego (powyższego) obszaru (Andriasyan i in., 2020)

6. DOSTĘPNE NARZĘDZIA

Na rynku dostępnych jest wiele gotowych rozwiązań, zarówno w formie osobnych programów, jak i wtyczek do konkretnych środowisk pracy. Jak wskazują badania, jednym z najczęściej wybieranych przez projektantów środowisk, oferujących możliwość zastosowania takich narzędzi jak algorytmy genetyczne, narzędzia generatywne itd., jest Grasshopper 3D dla Rhinoceros3D (Cichocka i in., 2017).

Z kolei jako najpopularniejsze narzędzia oferujące funkcjonalność algorytmów genetycznych dostępne dla platformy Grasshopper wymienić należy: wbudowany Galapagos czy też możliwy do zintegrowania zewnętrzny Wallacei czy Opossum.



Il. 13. Wykres przedstawiający preferowane środowiska pracy w zakresie narzędzi optymalizacyjnych przez projektantów (Cichocka i in., 2017)

6.1. WALLACEI

Wallacei jest silnikiem ewolucyjnym, który umożliwia użytkownikowi przeprowadzanie symulacji ewolucyjnych w środowisku Grasshopper 3D dzięki wykorzystaniu wysoce detalicznego, analitycznego narzędzia połączonego z wieloma wyczerpującymi metodami selekcji, które wspomagają użytkownika w lepszym zrozumieniu przeprowadzanych symulacji, a także w podejmowaniu bardziej świadomych decyzji na wszystkich etapach pracy nad symulacją; włączając w to wstępną konfigurację, analizę prezentowanych wyników i dobór rezultatów. Ponadto Wallacei umożliwia użytkownikowi późniejszą selekcję, rekonstrukcję i wyciąg dowolnego fenotypu po ukończeniu symulacji.

Wallacei, w postaci darmowego pluginu, jest zaprojektowany w sposób umożliwiający użytkownikowi szybkie i łatwe skorzystanie z jego pełnych możliwości oraz oferuje jasne sposoby analizy i selekcji wyników. Wallacei X z kolei bazuje na algorytmie NSGA-II (Deb i in., 2001) jako na algorytmie głównym, a także wykorzystuje Średnich-K (K-means) jako algorytmy grupujące. Ponadto Wallacei X zawiera w sobie biblioteki jMetal, LiveCharts oraz HelixToolkit (Mohammed, 2018).

6.2. OPOSSUM – OPTIMIZATION SOLVER WITH SURROGATE MODELS

Opossum zawiera dwa spośród najlepiej radzących sobie, jednozadaniowych algorytmów optymalizacyjnych w Grasshopperze; oparty na modelu RBFOpt i ewolucyjny CMA-ES⁵. Zawiera również wielozadaniowy RBFMOpt, a także wielozadaniowy MACO⁶ (algorytm mrówkowy), algorytmy MOEA/D⁷, NSGA-II⁸ oraz NSPSO⁹ (rój cząsteczek) z biblioteki Pygmo 2. RBFOpt wykorzystuje zaawansowane techniki uczenia maszynowego, aby znaleźć najlepsze rozwiązanie z możliwie małą liczbą założeń funkcji (ang. function evaluation), tj. symulacji, podczas gdy CMA-ES niezawodnie znajduje bliskie optymalnym rozwiązanie, gdy możliwe jest wykorzystanie wielu założeń funkcji (Wortmann, b.d.).

6.3. GALAPAGOS

Galapagos jest podstawowym silnikiem genetycznym zawartym w środowisku Grasshopper. Jego twórcą jest osoba odpowiedzialna również za Grasshoppera – David Rutten. Galapagos umożliwia podstawowe badania w zakresie symulacji genetycznych, oferując prostą obsługę w zamian za ograniczoną ilość otrzymywanych danych wyjściowych (Rutten, b.d.).

7. DYSKUSJA I WNIOSKI

Narzędzia generatywne, algorytmy genetyczne, automaty neuronowe i inne podobne narzędzia funkcjonują w przestrzeni teoretycznej od dekad, jednak to ostatnie lata przyniosły skok ich popularności i niemal powszechnego wykorzystania. Funkcjonalności, które te narzędzia oferują, czynią je niezwykle przydatnymi narzędziami w rękach projektantów, umożliwiając przeprowadzenie szybkich analiz na ogromnych ilościach danych, a następnie podejmowanie trafnych decyzji.

Analiza licznych badań sugeruje, że mimo iż nowoczesne narzędzia oferują dostęp do ogromnych zasobów informacji i odpowiedzi, nadal możemy nie dysponować wystarczająco

⁵ Covariance Matrix Adaptation Evolution Strategy – jeden z typów strategii optymalizacji numerycznej.

⁶ Multi-Objective Ant Colony Optimization Algorithm – jeden z rodzajów algorytmów wielozadaniowych optymalizacyjnych.

⁷ Multi-Objective Evolutionary Algorithm Based on Decomposition – jeden z rodzajów wielozadaniowych algorytmów ewolucyjnych oparty na rozkładzie.

⁸ Non-Dominated Sorting Genetic Algorithm II – szeroko wykorzystywany algorytm wielozadaniowy umożliwiający optymalizację wielu celów jednocześnie.

⁹ Non-Dominated sorting particle swarm optimization – zmodyfikowana wersja algorytmu optymalizacji roju.

precyzyjnie sformułowanymi pytaniami, które umożliwiłyby ich optymalne i adekwatne wykorzystanie.

Zdaniem autora, dysponując tak wszechstronnymi narzędziami, często bezrefleksyjnie skupiamy się na pojedynczych aspektach czy cechach przestrzennych, kompletnie przy tym pomijając inne. Takie podejście wydaje się ironiczne, pamiętając, że mocną stroną tych narzędzi jest wszechstronna analiza wielu aspektów i złożonych problemów, co powinno skłaniać ku wielowątkowym analizom i wyważonym, kompromisowym propozycjom, zamiast tworzeniu modelowych przykładów skupiających się na maksymalizacji pojedynczych współczynników.

BIBLIOGRAFIA

- Andriasyan, M., Zanelli, A., Yeghikyan, G., Asher, R., Haeusler, H. (2020). *Algorithmic Planning and Assessment of Emergency Settlements and Refugee Camps*. 38th eCAADe Conference 2020. <https://doi.org/10.52842/conf.ecaade.2020.2.115>
- Bajšanski, I.V., Milošević, D.D., Savić, S.M. (2015). Evaluation and improvement of outdoor thermal comfort in urban areas on extreme temperature days: Applications of automatic algorithms. *Building and Environment*, 94, 632–643. <https://doi.org/10.1016/j.buildenv.2015.10.019>
- Błażejczyk, K., Jendritzky, G., Bröde, P., Fiala, D., Havenith, G., Epstein, Y., Psikuta, A., Kampmann, B. (2013). An introduction to the Universal Thermal Climate Index (UTCI). *Geographia Polonica*, 86(1), 5–10. <https://doi.org/10.7163/GPol.2013.1>
- Cichocka, J., Browne, W.N., Rodriguez, E. (2017). *Optimization in the Architectural Practice – An International Survey*. 22nd International Conference of the Association for Computer-Aided Architectural Design Research in Asia (CAADRIA) 2017. <https://doi.org/10.52842/conf.caadria.2017.387>
- Cichocka, J., Łuczak, M. (2015). Generative design optimization in urban planning – walkability-optimized city concept. *ARCHITECTUS*. <https://doi.org/10.5277/ARC150110>
- Eiben, A. E., Raué, P.-E., Ruttkay, Z. (1994). *Genetic algorithms with multi-parent recombination*. W: Y. Davidor, H.-P. Schwefel, R. Männer (red.), *Parallel Problem Solving from Nature – PPSN III*, t. 866 (s. 78–87). Berlin–Heidelberg: Springer. https://doi.org/10.1007/3-540-58484-6_252
- Evans, B., Walton, S.P. (2017). Aerodynamic optimisation of a hypersonic reentry vehicle based on solution of the Boltzmann – BGK equation and evolutionary optimisation. *Applied Mathematical Modelling*, 52, 215–240. <https://doi.org/10.1016/j.apm.2017.07.024>
- Fink, T., Koenig, R. (2019). Integrated Parametric Urban Design in Grasshopper / Rhinoceros 3D Demonstrated on a Master Plan in Vienna. *Blucher Design Proceedings*, 7(1), 313–322. https://doi.org/10.5151/proceedings-ecaadesigradi2019_398

- Goldstein, D. (2016). *How a high 'walk score' boosts your home's value. One point can add nearly 1% to a property's sale price*. MarketWatch. Pobrane z: <https://www.marketwatch.com/story/how-walk-score-boosts-your-homes-value-2016-08-11> (dostęp: 12.04.2025).
- Gross, B. (reż.). (2003). *A solar energy system that tracks the sun (TED)*. Film: https://www.ted.com/talks/bill_gross_a_solar_energy_system_that_tracks_the_sun (dostęp: 19.04.2025).
- Hornby, G., Globus, A., Linden, D., Lohn, J. (2006). *Automated Antenna Design with Evolutionary Algorithms*. W: *Space 2006*. 19–21 września, San Jose, CA. <https://doi.org/10.2514/6.2006-7242>
- Laurini, R. (1998). *Fundamentals of Spatial Information Systems*. Londyn: Academic Press.
- Martello, S., Toth, P. (1990). *Knapsack problems: Algorithms and computer implementations*. New York: J. Wiley Sons.
- Melanie, M. (1998). *An Introduction to Genetic Algorithms*. Londyn: The MIT Press.
- Mohammed, M. (2018). About the Wallacei platform. Pobrane z: <https://www.wallacei.com/about> (dostęp: 12.04.2025).
- NASA. (2006). ST5 – Antena xBand. Pobrane z: https://en.wikipedia.org/wiki/Evolved_antenna#/media/File:St_5-xband-antenna.jpg (dostęp: 07.04.2025).
- Navarro-Mateu, D., Makki, M., Cocho-Bermejo, A. (2018). Urban-Tissue Optimization through Evolutionary Computation. *Mathematics*, 6(10), 189. <https://doi.org/10.3390/math6100189>
- Ogawa, H. (1986). Labeled point pattern matching by Delaunay triangulation and maximal cliques. *Pattern Recognition*, 19(1), 35–40. [https://doi.org/10.1016/0031-3203\(86\)90029-4](https://doi.org/10.1016/0031-3203(86)90029-4)
- Petrowski, A. (2017). *Evolutionary Algorithms*. Somerset: Wiley.
- Rakha, T., Reinhart, Ch. (2012). *Generative Urban Modeling: A Design Work Flow For Walkability – Optimized Cities*. Pobrane z: https://web.mit.edu/sustainabledesignlab/publications/SimBuild2012_WalkableCityConcept.pdf (dostęp: 07.04.2025).
- Ruthen, D. (2010, wrzesień 24). *Evolutionary Principles* [post]. Pobrane z: <https://www.grasshopper3d.com/profiles/blogs/evolutionary-principles> (dostęp: 22.03.2025).
- Rutten, D. (b.d.). *Galapagos – Evolutionary Solver*. Pobrane z: <http://grasshopperdocs.com/addons/galapagos.html> (dostęp: 01.05.2023).
- Safe, M., Carballido, J., Ponzoni, I., Brignole, N. (2004). *On Stopping Criteria for Genetic Algorithms*. W: A.L.C. Bazzan, S. Labidi (red.), *Advances in Artificial Intelligence SBIA 2004*, t. 3171 (s. 405–413). Berlin–Heidelberg: Springer. https://doi.org/10.1007/978-3-540-28645-5_41
- Saratsis, E., Dogan, T., Reinhart, C.F. (2017). Simulation-based daylighting analysis procedure for developing urban zoning rules. *Building Research & Information*, 45(5), 478491. <https://doi.org/10.1080/09613218.2016.1159850>
- Shi, Z., Fonseca, J.A., Schlueter, A. (2021). A parametric method using vernacular urban block typologies for investigating interactions between solar energy use and urban design. *Renewable Energy*, 165, 823–841. <https://doi.org/10.1016/j.renene.2020.10.067>

- Taherdangkoo, M., Paziresh, M., Yazdi, M., Bagheri, M. (2013). An efficient algorithm for function optimization: Modified stem cells algorithm. *Open Engineering*, 3(1), 36–50. <https://doi.org/10.2478/s13531-012-0047-8>
- Vanderbilt, T. (2012). *What's Your Walk Score? The company that puts a number on walkability*. Pobrane z: https://www.slate.com/articles/life/walking/2012/04/walking_in_america_how_walk_score_puts_a_number_on_walkability_html (dostęp: 12.04.2025).
- WalkScore. (b.d.). *WalkScore*. Pobrane z: <https://www.walkscore.com/> (dostęp: 12.04.2025).
- Whitley, D. (1994). A genetic algorithm tutorial. *Statistics and Computing*, 4(2). <https://doi.org/10.1007/BF00175354>
- Wolpert, D.H., Macready, W.G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67–82. <https://doi.org/10.1109/4235.585893>
- Wortmann, T. (b.d.). OPOSSUM – OPTIMIZATION SOLVER WITH SURROGATE MODELS (by Opossum Support). Pobrane z: <https://www.food4rhino.com/en/app/opossum-optimization-solver-surrogate-models> (dostęp: 01.05.2023).
- Xu, X., Yin, C., Wang, W., Xu, N., Hong, T., Li, Q. (2019). Revealing Urban Morphology and Outdoor Comfort through Genetic Algorithm-Driven Urban Block Design in Dry and Hot Regions of China. *Sustainability*, 11(13), 3683. <https://doi.org/10.3390/su11133683>