



Architecture
and town planning
Quarterly

Kwartalnik architektury
i urbanistyki



Architecture
and town planning
Quarterly
Kwartalnik architektury
i urbanistyki

3/2025
tom LXX
ISSN 1644-2449
ISSN e012-9846



Krzysztof Nazar, *Generatywna sztuczna inteligencja w edukacji architektonicznej: studium wykorzystania modeli dyfuzyjnych przy projektowaniu koncepcyjnym*, „Kwartalnik Architektury i Urbanistyki”, t. LXX, 2025, z. 3, s. 17-38

Krzysztof Nazar, *Generative artificial intelligence in architectural education: a study of the use of diffusion models in conceptual design*, "Architecture and Town Planning Quarterly", vol. LXX, 2025, no. 3, pp. 17-52
[English version pp. 39-52]

DOI: 10.17388/WUT.2025.0062.ARCH

Generatywna sztuczna inteligencja w edukacji architektonicznej: studium wykorzystania modeli dyfuzyjnych przy projektowaniu koncepcyjnym

Streszczenie

Artykuł przedstawia studium zastosowania generatywnej sztucznej inteligencji (AI) we wczesnej fazie projektowania architektonicznego. Celem było sprawdzenie, czy narzędzia te przyspieszają tworzenie koncepcji oraz jak zwiększyć nad nimi kontrolę poprzez proste modele parametryczne i jasno zdefiniowaną pętlę decyzji z udziałem człowieka. Badanie oparto na kursie prowadzonym na Wydziale Architektury Politechniki Warszawskiej przez zespół prowadzących z Katedry Projektowania Architektonicznego i Zakładu Projektowania Prośrodowiskowego. W kursie wzięło udział 62 studentów w 25 zespołach. Kurs został podzielony na cztery bloki (eksploracja typów i wizualizacje, automatyzacja układów funkcjonalnych, analizy nasłonecznienia, ocena cyklu życia) – w pracy opisany szczegółowo jest pierwszy z nich. Na zajęciach połączono modelowanie parametryczne z generatorem obrazów sterowanym tekstem i obrazem. Wyniki ankiet przeprowadzonych wśród studentów na końcu kursu wskazują, że AI była użyteczna na etapie koncepcji dla 88% z nich; główne bariery dotyczyły ograniczonej przewidywalności, powtarzalności i wymagań sprzętowych. Najlepsze rezultaty dawało połączenie jasno określonej intencji projektanta z prostym modelem 3D i krytyczną selekcją wyników. Autorzy kursu rekomendują włączanie AI do programu studiów jako nauki pracy z procesem (formułowanie kryteriów, kontrola przebiegu, ocena wyników), a nie wyłącznie obsługi narzędzi skoncentrowanej na wyniku.

Słowa kluczowe projektowanie generatywne | generatywna sztuczna inteligencja | modelowanie parametryczne | modele dyfuzyjne | dydaktyka projektowania | wizualizacja architektoniczna

Krzysztof Nazar, mgr inż. arch.
Wydział Architektury
Politechnika Warszawska

Krzysztof Nazar, MSc Arch.
Faculty of Architecture
Warsaw University of Technology

1. Problem badawczy i zakres artykułu

Artykuł opisuje fragment kursu akademickiego, który został poświęcony wykorzystaniu sztucznej inteligencji (AI) na wczesnym etapie projektowania architektonicznego. Celem badania było określenie, czy sztuczna inteligencja ma potencjał

ułatwienia lub polepszenia wyników pracy koncepcyjnej oraz jak można poprawić jej działanie poprzez wykorzystanie modelu parametrycznego jako dodatkowej warstwy kontroli.

W pierwszej części zaprezentowano obecne tendencje w praktyce projektowej i dydaktycznej, które wskazują na coraz powszechniejsze wykorzystanie narzędzi opartych na sztucznej inteligencji. Opis ten jest zakończony uzasadnieniem podjęcia tematu. Dalej przedstawiono wcześniejsze przykłady wprowadzenia sztucznej inteligencji na kursach na studiach architektonicznych. Następną część stanowi opis autorskiego scenariusza zajęć, który zrealizowaliśmy w zespole: dr inż. arch. Krystian Kwieciński, dr inż. arch. Szymon Płoszaj-Mazurek, mgr inż. arch. Krzysztof Nazar i mgr inż. arch. Jakub Oszczyk na siódmym semestrze jednolitych studiów magisterskich na kierunku Architektura na Wydziale Architektury Politechniki Warszawskiej. Kolejne rozdziały poświęcone są konfiguracji oprogramowania, niezbędnej do replikacji zajęć, opisowi zadań projektowych postawionych przed studentami oraz treściom ankiet, stanowiących podstawę do oceny wdrożenia. Artykuł kończy się przedstawieniem wyników zajęć, dyskusją i oceną zasadności nauczania wykorzystania sztucznej inteligencji na kursach na studiach architektonicznych.

2. Wstęp

Ostatnie lata to w architekturze czas „projektowania wspieranego przez AI”. Sztuczna inteligencja nie zastępuje projektanta, lecz poszerza jego pole widzenia – pozwala szybciej weryfikować różne twórcze tropy i tym samym sprawniej podejmować decyzje. Modele dyfuzyjne (generatory obrazów AI) należy traktować jako partnera na etapie pierwszych szkiców, a nie „autora” projektu – ocena i odpowiedzialność za wybory pozostają po stronie człowieka¹. Skoro coraz częściej oddajemy maszynom część pracy twórczej, sensownie jest odejść od opozycji „narzędzie kontra twórca” i myśleć o współpracy oraz współautorstwie. Tak rozumiane wsparcie opisuje m.in. Philip F. Yuan: maszyny wzmacniają percepcję, myślenie i wyobraźnię architektów, zamiast je zastępować².

Raport Royal Institute of British Architects (RIBA) z 2024 roku, opracowany na podstawie ankiety przeprowadzonej wśród członków stowarzyszenia, pokazuje rosnące zainteresowanie stosowaniem AI w architekturze połączone z ostrożnym wdrażaniem: 41% pracowni korzysta z AI przynajmniej okazjonalnie, chociaż tylko 2% w każdym projekcie (59% nigdy)³. Wśród korzystających 43% już deklaruje poprawę efektywności procesu projektowego. W perspektywie 2 lat przeważają oczekiwania szerszego wdrożenia: wykorzystania AI we własnym biurze spodziewa się 54%, a wynikającej z rozwoju technologii poprawy efektywności 57%. Jednocześnie tylko 20% biur inwestuje w prace B+R nad AI (wdrożenia i studia przydatności), co tłumaczy, dlaczego w edukacji istotne jest uczenie procedur, kryteriów oceny

¹ D. Bolojan, *Creative AI: Augmenting Design Potency*, „Architectural Design”, 2022, nr 92(3), s. 22–27.

² P. F. Yuan, *Toward a generative AI-augmented design era*, „Architectural Intelligence”, t. 2, 2023, nr 1, art. 16.

³ Royal Institute of British Architects, *RIBA AI Report 2024*, <https://www.architecture.com/knowledge-and-resources/resources-landing-page/riba-ai-report-2024> (dostęp 31.10.2025).

i dokumentacji pracy z gotowymi narzędziami, które pracują na zasadzie „black-box” (kiedy nie znamy dokładnie mechanizmów działania).

Phil Bernstein przekonuje, że włączenie sztucznej inteligencji do zawodu architekta nie jest rewolucją narzuconą z zewnątrz, tylko kolejnym etapem rozwoju po CAD, BIM i modelowaniu parametrycznym. AI zaczyna wspierać architektów w codziennej rutynie projektowej: nie tylko przez „rysowanie” i modelowanie, lecz także analizy oraz przewidywanie skutków decyzji projektowych. Natomiast w przygotowaniu dokumentacji – automatyzację i mniej kosztowne poprawki na późniejszych stadiach projektu⁴. To przesunięcie będzie coraz mocniej odczuwalne w praktyce: systemy oparte na uczeniu maszynowym mają rozszerzać nasze kompetencje – nie zastępują architektów, ale wpływają na sposób pracy, reorganizując podział ról⁵. Dla edukacji oznacza to wskazówkę, żeby unikać błędu popełnionego przy nauczaniu metod modelowania BIM, które często sprowadzano do obsługi programu, bez przełożenia na sposób myślenia i realne procesy w pracowniach projektowych. Trzeba włączyć AI do programu studiów nie jako kolejny kurs narzędziowy, lecz jako ćwiczenie osławające z nowymi rolami, które musi pełnić architekt. Należy uczyć pracy na dużych zbiorach danych, definiowania jasnych i mierzalnych kryteriów oceny generowanych utworów, łączenia modeli parametrycznych z analizą i oceną wyników oraz współpracy człowieka z algorytmem w realnych scenariuszach projektowych⁶. Szerszy kontekst tych przemian wyznacza dyskurs *zwrotów cyfrowych* w architekturze – od informatyzacji reprezentacji i wytwarzania po narzędzia przejmujące obliczenia, myślenie i wnioskowanie – syntetycznie ujęty w pracach Mario Carpo i Neila Leacha⁷.

W ostatnich dziesięciu latach zainteresowanie AI w projektowaniu budynków i miast mocno przyspieszyło, co pokazuje artykuł przeglądowy Haolan Zhang i Ruichuan Zhang⁸. Do 2018 r. liczba publikacji na temat AI w projektowaniu architektury i urbanistyki była raczej umiarkowana, a po 2019 r. widać wyraźny wzrost. Mapa słów kluczowych pokazuje też zmianę akcentów: dyskurs przesunął się z *computer-aided design* i *topology optimization* w stronę metod sztucznej inteligencji, takich jak *deep learning* i *generative adversarial network*. Autorzy przeglądu zebrali łącznie 179 prac z ostatniej dekady, porządkując je według trzech pól zastosowań – projekt zagospodarowania (urbanistyka), wnętrza, elewacje – oraz trzech klas metod: systemy eksperckie, optymalizacja i uczenie maszynowe. Autorzy udowadniają, że AI dotyka dziś pełnego spektrum zadań: od planowania zagospodarowania terenu po detal fasady. Daje to obraz szybko rosnącej i coraz lepiej standaryzowanej dziedziny badań nad AI w projektowaniu architektury i urbanistyki. Inny systematyczny przegląd (z lat 2015–2025), dokonany przez Socratesa Yiannoudesa, pokazuje, że 85% badanych rozwiązań generatywnej AI w architekturze kończy się na obrazie

⁴ P. Bernstein, *Machine Learning; Architecture in the Age of Artificial Intelligence*, London 2022, s. 9–10.

⁵ Op. cit., s. 103.

⁶ Op. cit., s. 105–106.

⁷ M. Carpo, *The Digital Turn in Architecture 1992–2012*, Chichester 2012, s. 8–14; idem, *The Second Digital Turn: Design Beyond Intelligence*, Cambridge, MA 2017, s. 1–8; N. Leach, *Architecture in the Age of Artificial Intelligence: An Introduction to AI for Architects*, London–New York 2022, rozdz. 5–7.

⁸ H. Zhang, R. Zhang, *Generative artificial intelligence (AI) in built environment design and planning – A state-of-the-art review*, „Progress in Engineering Science”, t. 2, 2025, nr 1.

rastrowym lub nieedytowalnej geometrii, a tylko 15% dostarcza modele, które można wykorzystać w oprogramowaniu CAD lub BIM⁹. Równocześnie 69% metod ogranicza się do pracy koncepcyjnej. Daje to obraz ograniczeń i branżowych tendencji.

Wybór tematu i cel artykułu wynikają z dwóch przesłanek. Po pierwsze – potrzeba przystępnego i zwięzłego scenariusza dydaktycznego, który nauczy studentów sterowania modelami dyfuzyjnymi za pomocą prostych, jawnych warunków (definicje słowne wsparte ograniczeniami geometrycznymi). Celem jest oswojenie z narzędziem, wokół którego rosną mity i obawy związane z przyszłością zawodu. Drugą przesłanką jest konieczność osadzenia narzędzi opartych na AI w logice myślenia algorytmicznego, gdzie reguły postępowania i kryteria oceny są równie ważne, co wyniki. Poza nauczeniem korzystania z narzędzia niezbędne jest rozpoczęcie dyskusji na temat zmian w praktyce projektowej, które wynikną z rozwoju technologicznego.

3. Tło badań

Badania nad projektowaniem generatywnym i algorytmicznym w architekturze mają długą genealogię, która wykracza daleko poza ostatnią falę popularności AI. W nurcie *parametric design thinking* (PDT) projekt opisuje się jako schemat relacji (parametrów i zależności) generujący całe rodziny rozwiązań oraz pozwalający na szybkie, odwracalne re-edycje, zwykle w interfejsach VPL (*visual programming language*) łączących kod i geometrię (np. Rhinoceros+Grasshopper). Rivka Oxman porządkuje te praktyki i pętle decyzyjne w modelu przepływu R-E-P-G (*representation–evaluation–performance–generation*): zmiana reguły natychmiast przebudowuje model i pozwala na przejście do oceny. Co równie ważne, interfejsy projektowania parametrycznego czynią reguły generatywne widocznymi i edytowalnymi „na żywo”. To właśnie dlatego parametryka naturalnie uczy pracy nad przestrzenią projektową, a nie na jednym „finalnym” wyniku (projektowanie generatywne kontra projektowanie bezpośrednie)¹⁰.

Na Wydziale Architektury Politechniki Warszawskiej powstała spójna pedagogika modelowania parametrycznego, która została opisana przez Jana Słyka, Karolinę Ostrowską-Wawryniuk i Marcina Strzałę. W opracowanym tam modelu zajęć proponuje się trzy fazy: analityczną (redukcja przypadku projektowego do algorytmu zapisanego krok po kroku), aplikacyjną (implementacja algorytmu za pomocą VPL – Grasshopper) i eksploracyjną (systematyczne przeszukiwanie wariantów modelu parametrycznego). Ważnym ćwiczeniem jest „grupa kontrolna”: jeden zespół studentów rekonstruuje przypadek projektowy wyłącznie z instrukcji spisanych przez inny. Ta zamiana ról potrafi ujawnić niejednoznaczności i wymusza precyzję sformułowań. Takie doświadczenie okazuje się cenne przy pracy z AI, ponieważ zwiększa umiejętność przewidywania, że zapisane polecenia mogą zostać błędnie zinterpretowane. Co istotne, autorzy raportują wyraźny wzrost skuteczności kursu (ponad 50% więcej zaliczeń), gdy ciężar zajęć przesunięto z „obsługi narzędzi” na myślenie

⁹ S. Yiannoudes, *Shaping Architecture with Generative Artificial Intelligence: Deep Learning Models in Architectural Design Workflow*, „Architecture”, t. 5, 2025, nr 4, s. 1–24.

¹⁰ R. Oxman, *Thinking difference: Theories and models of parametric design thinking*, „Design Studies”, 2017, t. 52, s. 4–39.

algorytmiczne i świadome definiowanie parametrów¹¹. Jest to zgodne z postulatami Bernsteina odnośnie „pedagogiki nowych narzędzi” opisanymi we wstępie.

W ostatnich latach w nurcie *computational design* coraz częściej porusza się problematykę obrazowania generatywnego za pomocą AI. Joern Ploennigs i Markus Berger porównują systemy generowania obrazów Midjourney, DALL-E 2 i Stable Diffusion, pokazując, że iteracyjna praca (średnio przynajmniej cztery „kroki” do „dobrego” obrazu), operacje maskowania (*in-/out-painting*) oraz dostosowywanie ustawień (w szczególności wag poszczególnych warstw sterowania) stają się praktycznym „językiem kontroli” – odpowiednikiem parametrów w modelu geometrycznym. Zaprezentowany przez nich schemat opracowania elewacji łączy wstępną ideację w Midjourney, rozszerzanie kadru (*outpainting*) i podmiany (*inpainting*) w DALL-E 2 oraz uszczegółowienie w Stable Diffusion. Autorzy zauważają ograniczenia narzędzi AI w warstwie semantycznej: generatywne rzuty i przekroje pozbawione są niezbędnej precyzji i jednoznaczności¹².

Opisany przez Lucynę Nykę, Jana Cudzika i Jakuba Szczepańskiego eksperyment dydaktyczny „Green campus” dokumentuje wpływ obrazowania AI w *research-by-design studio*. W dwuletnim układzie porównawczym (rok bez AI kontra rok z AI) zidentyfikowano trzy wzorce pracy: a. półtradycyjny (AI wyłącznie jako inspiracja), b. hybrydowy (wykorzystanie wygenerowanych obrazów w pracy projektowej) oraz c. hybrydowo-interaktywny (wpływanie na generowane obrazy poprzez dodatkowe warstwy kontroli), przy czym ta ostatnia ścieżka dawała wg autorów najlepsze rezultaty. Autorzy raportują przyspieszenie tworzenia materiału koncepcyjnego (tablice inspiracji – *mood boards*, warianty rozwiązań) oraz otwieranie „ścieżek myślenia” w pierwszych tygodniach kursu; równolegle wskazują trudność akceptacji ostatecznych koncepcji projektowych wobec „łatwości” generowania i postulują przesunięcie oceny prac studentów z końcowego rezultatu na kompetencje w zakresie projektowania i kontrolowania procesów¹³.

Interesującym odniesieniem jest studium kursu, w którym AI wpleciono w dziewięć tygodni projektowania – od kwerend i programowania funkcjonalnego (z wykorzystaniem dużych modeli językowych – LLM) po koncepcję i dopracowanie wizualizacji (za pomocą modeli dyfuzyjnych). Shitao Jin i in. pokazują, że taka integracja pozytywnie wpływa na proces projektowy: średnia samoocena „ogólnej skuteczności” wzrosła z 2,71 do 4,04 na możliwe 5. Studenci najczęściej akcentowali dwa pozytywne czynniki: narzędzia oparte na AI stymulują innowacyjne myślenie oraz realnie podnoszą wydajność pracy. Jednocześnie wyżej oceniali wsparcie AI przy porządkowaniu informacji i decyzji programowych (praca na tekście), niż w samej syntezie formy (obrazy), co wiązano z ograniczoną kontrolowalnością modeli dyfuzyjnych. Autorzy artykułu zalecają, by łączyć generowanie obrazów z parametryczną podstawą (Rhino+Grasshopper lub oprogramowanie BIM). Może to zainspirować klarowny

¹¹ J. Słyk, K. Ostrowska-Wawryniuk, M. Strzała, *Form Follows Parameter: Algorithmic Thinking Oriented Course for Early Stage Architectural Education*, „Nexus Network Journal”, t. 24, 2022, nr 2, s. 503–522.

¹² J. Ploennigs, M. Berger, *AI art in architecture*, „AI in Civil Engineering”, t. 2, 2023, nr 1, art. 8.

¹³ J. Cudzik, L. Nyka, J. Szczepański, *Artificial intelligence in architectural education – green campus development research*, „Global Journal of Engineering Education”, 2024, nr 26(1), s. 20–25.

podział w dydaktyce: modele językowe wykorzystywane do opracowania programu projektu i analizy wymagań, generatory obrazów do szybkiego szerokiego przeglądu inspiracji, a model parametryczny jako warstwa sterująca. Wyniki badań wskazują, że modele dyfuzyjne są najbardziej użyteczne na wczesnym etapie projektowania¹⁴.

Propozycja warsztatowa „AI-assisted architectural design studio” (AI-a-ADS) również lokuje modele dyfuzyjne na początku pracy projektowej – jako katalizator pomysłów. W trzyczęściowych zajęciach autorzy zaplanowali kolejno: 1. odtworzenie słów kluczowych na podstawie szkiców oraz modeli wykonanych przez studentów, 2. wprowadzenie słów kluczowych do szablonu promptu w narzędziu Midjourney w celu wygenerowania wizualizacji przekroju budynku, 3. wykorzystanie modelu przekroju do ostatecznego dostosowania wyniku (*blend images*). Wyniki ankiet przeprowadzonych na koniec zajęć wskazały, że studenci docenili możliwość poznania narzędzi opartych na sztucznej inteligencji, jednocześnie stwierdzając, że wyniki jej działania były generalnie nieprzydatne i nie zostały wykorzystane w projektach¹⁵.

Warto również odnotować studium, które systemowo wprowadza silnik renderujący AI do toku prac w studiu projektowym. W kursie „micro-house” studenci drugiego roku przechodzili od klasycznej analizy miejsca i precedensów, przez rysunki 2D, do bryłowej analizy chłonności 3D, a następnie w trzech krokach łączyli własny model z narzędziem AI: krok 1. wyłącznie bryły bez materiałów, 2. generowanie wariantów i odpowiedzi na podstawie sceny 3D, 3. finalna wizualizacja służąca ocenie materiałów i detalu. Próba obejmowała 8 projektów; ocenę przeprowadzono m.in. pod kątem kreatywności, funkcjonalności, wykonalności i zgodności z programem. Abdulrahman Ahmed A. Alymani raportuje poprawę jakości i złożoności rozwiązań w trakcie semestru (zarówno w danych ilościowych, jak i jakościowych), a także skrócenie czasu realizacji zadań. Mechanizm działania opisano jako powtarzalne pętle informacji zwrotnych (*prompt-image-evaluation loops*). Wizualizacja AI umożliwiła szybkie próby wariantów materiałowych i świetlnych oraz iteracyjną weryfikację rozwiązań. W opisie studiów przypadków pojawiają się korekty, które wynikły z szerokiego przeglądu: m.in. dopasowanie geometrii i komunikacji do topografii terenu, zmiana układu komunikacji czy wprowadzenie określonej artykulacji bryły albo konkretnego materiału¹⁶.

Na tle powszechnego korzystania z gotowych modeli AI warto odnotować równoległą ścieżkę eksperymentowania, która wymaga większej biegłości technicznej: trenowanie narzędzi na zbiorach samodzielnie dobieranych i etykietowanych obrazów. Ma to zapewnić z jednej strony większą zgodność wyników z intencjami, a z drugiej pewną dozę unikalności rozwiązań. Anca-Simona Horvath i Panagiota

¹⁴ S. Jin et al., *Enhancing Architectural Education through Artificial Intelligence: A Case Study of an AI-Assisted Architectural Programming and Design Course*, „Buildings”, t. 14, 2024, nr 6, s. 14–16.

¹⁵ G. Özorhon et al., *AI-assisted architectural design studio (AI-a-ADS): How artificial intelligence join the architectural design studio?*, „International Journal of Technology and Design Education”, t. 35, 2025, nr 5, s. 1999–2023.

¹⁶ A. A. A. Alymani, *Integrating Artificial Intelligence Rendering Tools in Design: Integrating AI as teaching methods in architectural education*, w: *Data-Driven Intelligence. Proceedings of the 42nd Conference on Education and Research in Computer Aided Architectural Design in Europe (eCAADe 2024)*, t. 2, red. O. Kontovourkis, M. C. Phocas, G. Wurzer, Nicosia 2024, s. 629–638.

Pouliou opisują proces trenowania modeli generatywnych na podstawie tekstów z „Architectural Design” i konkursu eVolo oraz 480 plakatów eVolo¹⁷. Celem było wygenerowanie kompletnej pracy konkursowej. Autorki wykazały, że bezpośredni wpływ na zbiory danych do trenowania modeli dał im poczucie większej sprawczości nad rezultatem. Wiązało się to jednak z kosztem: algorytmy uczenia maszynowego wymagają bardzo dużych zbiorów obrazów, które dodatkowo należy poprawnie opisać (etykietować). Czas poświęcony temu zadaniu mógłby zostać poświęcony na tradycyjną twórczą pracę. W ich wypadku proces projektowania przesunął się ze szkicowania i zespołowych dyskusji na pracę z językami programowania i zbiorami danych. Z drugiej strony proces porządkowania danych na temat „co zostało już wcześniej zrobione” był bardzo pouczający i pozwolił zaobserwować wzorce skutecznych prac z poprzednich edycji. Autorki wskazują nawet, że budowanie bazy danych do uczenia maszynowego mogłoby samo w sobie być dobrym narzędziem do nauczania historii i teorii projektowania i sztuki, ponieważ przekierowuje uwagę na szukanie ukrytych zależności w pozornie niepowiązanych treściach.

Przedstawiony kontekst wskazuje na konsensus co do trzech elementów wspólnych: 1. produktywną rolę szerokiego przeszukiwania (modele dyfuzyjne) zdefiniowanego przez jasne warunki wejściowe; 2. potrzebę wprowadzenia dodatkowych, wizualnych warstw sterujących, np. za pomocą autorskiego szkicu lub modelu parametrycznego; 3. wymóg udziału człowieka jako krytyka i moderatora procesu generatywnego (*human-in-the-loop*, HIL). Prezentowane w niniejszym artykule ćwiczenie – łączące model dyfuzyjny Stable Diffusion z prostym modelem parametrycznym w Rhinoceros+Grasshopper oraz jawnie zdefiniowaną pętlą ewaluacji – adresuje te trzy elementy i podejmuje próbę usystematyzowania sposobu włączenia generatywnej sztucznej inteligencji w edukację *computational design*.

4. Metoda badawcza

Analizowany poniżej kurs trwał 25 godzin dydaktycznych i obejmował 4 grupy studenckie. Tematem zajęć było zaprojektowanie domu jednorodzinnego w taki sposób, by maksymalnie wykorzystać dostępne cyfrowe narzędzia generatywne i ograniczyć własną pracę do roli recenzenta procesów realizowanych przez komputer. Studentom zadaliśmy spekulatywne pytanie: „Czy jesteśmy na etapie rozwoju technologicznego, na którym komputery, a szczególnie sztuczna inteligencja, mogą zastąpić projektanta?” Kurs podzieliliśmy na cztery pięciogodzinne bloki warsztatowe, po kolei: 1. eksploracja typów, parametryzacja i generowanie obrazów za pomocą AI; 2. automatyzacja generowania układów funkcjonalnych z wykorzystaniem algorytmów optymalizacyjnych; 3. analizy nasłonecznienia; 4. środowiskowa ocena cyklu życia – *life cycle assessment* – LCA. Ostatnie, piąte pięciogodzinne zajęcia przeznaczyliśmy na prezentacje prac i dyskusję. Szczegółowy opis bloków znajduje się w kolejnym rozdziale. Jak wspomniano wcześniej, świadomie ograniczyliśmy charakter udziału studentów w procesie projektowania do roli *human-in-the-loop*: pełnili oni rolę moderatorów i krytyków

¹⁷ A.-S. Horvath, P. Pouliou, *AI for conceptual architecture: Reflections on designing with text-to-text, text-to-image, and image-to-image generators*, „Frontiers of Architectural Research”, t. 13, 2024, nr 3, s. 593–612.

automatycznych procesów, które przygotowaliśmy jako scenariusze zajęć. Kluczowe dla badań było zebranie po każdym bloku wyników prac studentów wraz z ich refleksją na temat przydatności wykorzystanych metod generatywnych. W zajęciach wzięło udział 62 studentów, którzy stworzyli 25 grup roboczych liczących po 2–3 osoby. Niniejszy artykuł opisuje w szczególności pierwszy blok warsztatowy i omawia jego wyniki.

4.1. Opis poszczególnych bloków warsztatowych

Blok 01 (eksploracja i typologia), poprowadzony został przez autora artykułu. Warsztaty obejmowały parametryzację bryły domu jednorodzinnego oraz metody przeszukiwania przestrzeni rozwiązań z użyciem modelowania parametrycznego (Rhinceros+Grasshopper) i generatywnego obrazowania (Stable Diffusion). Uczestnicy realizowali sekwencję: szerokie generowanie wariantów → identyfikacja „typu”, zdefiniowanie go za pomocą słownego opisu i parametryzacja w programie Grasshopper → sprzężenie zwrotne z modelem dyfuzyjnym (wizualizacje + odpowiedzi/promptowanie) w celu iteracyjnego doprecyzowania intencji projektowej. Uzyskane efekty to: mozaiki wariantów, diagram parametryzacji, finalna wizualizacja AI oraz opis ostatecznej definicji typu. Refleksja końcowa dotyczyła roli generatywnego obrazowania na wczesnym etapie, jego trudności oraz relacji do źródeł inspiracji online i miejsca AI w warsztacie projektanta.

Blok 02 (generowanie podziału funkcjonalnego), poprowadzony przez mgr. inż. arch. Jakuba Oszczyka, to porównanie dwóch strategii tworzenia rzutów funkcjonalnych domów jednorodzinnych: manualnej i zautomatyzowanej (Rhinceros+Grasshopper). W części manualnej studenci dokumentowali własny przebieg pracy, rozpoznając zalety, wady i możliwe usprawnienia; w części zautomatyzowanej projektowali za pomocą przygotowanego przez prowadzącego systemu generatywnego, dokumentowali iteracje i konfrontowali je z rezultatami ręcznymi.

Blok 03 (nasłonecznienie), poprowadzony przez dr. inż. arch. Krystiana Kwiecińskiego obejmował analizę nasłonecznienia domów jednorodzinnych: symulacje zacienienia działki dla równonocy oraz przesilen letniego i zimowego, a także ocenę doświetlenia z użyciem metryk *daylight factor*, *daylight autonomy* oraz *useful daylight illuminance*. Analizy przeprowadzano w programie Rhinceros+Grasshopper za pomocą rozszerzeń Ladybug i Honeybee. Na ich podstawie opracowano Wariant 1 i zmodyfikowany Wariant 2 (korekta lokalizacji i wielkości przeszkleń, dodanie elementów zacieniających) i porównano je pod kątem poprawy nasłonecznienia pomieszczeń.

Blok 04 (LCA i ślad węglowy) został poprowadzony przez dr. inż. arch. Mateusza Płoszaja-Mazurka. Były to ocena cyklu życia w projektowaniu domów jednorodzinnych i pokazanie, jak analizy środowiskowe kształtują decyzje projektowe. Studenci wykonywali przykładowe obliczenie ręczne dla wybranej przegrody, robili przedmiar głównych przegród i obliczali ślad węglowy wbudowany bazowej koncepcji. Następnie proponowali warianty materiałowe i konstrukcyjne (warstwy przegród, technologia, bryła), porównując ich wpływ na wynik i prezentując udział komponentów w całkowitym śladzie.

Prace końcowe były oceniane na podstawie jakości udokumentowania przeprowadzonych eksperymentów. Zwracaliśmy uwagę przede wszystkim na świadome

korzystanie z narzędzi potwierdzone opisami, a w mniejszym stopniu na uzyskane rezultaty. Kompilacja efektów ze wszystkich czterech bloków warsztatowych ostatecznie była prezentowana na jednej planszy projektowej. Ilustracje 1a–1d przedstawiają przykładową planszę końcową wykonaną wg narzuconego przez nas schematu, wyraźnie pokazującego kolejność prac (il. 1a–1d). Oryginalnie plansze składane były w pionie z układem bloków w jednej kolumnie od pierwszego na górze, a czwartego na dole planszy.

4.2. Założenia i konfiguracja do replikacji procesu

Przed zajęciami autor przygotował wszystkie stanowiska w pracowni komputerowej, wgrywając niezbędne oprogramowanie i ujednolicając ustawienia, by zwiększyć porównywalność rezultatów. Opis konfiguracji komputerów znajduje się w załączniku nr 1 do artykułu.

Z uwagi na ograniczony czas przeznaczony na warsztaty (5 godzin) autor zastosował ustandaryzowany *prompt* bazowy i *prompt* negatywny, aby ograniczyć liczbę prób i błędów oraz zwiększyć porównywalność. *Prompt* to tekstowa wskazówka dla modelu dyfuzyjnego, która określa, co ma (lub nie ma) zostać wygenerowane.

Prompt bazowy: *large house with slant roof. simple architectonic ((physical model)). minimalist, simplistic, conceptual. isometric view from the top, typology.*

Prompt negatywny: *rendering, photography, visualization, digital art, grass, trees. photo, sketchup, sketch, small, no roof.*

Na początku zajęć studenci otrzymali szablony arkuszy do wypełnienia informacjami o wynikach swojej pracy. Miały się na nie składać: mozaiki wariantów otrzymanych z AI, definicja typu domu, diagramy jego parametryzacji, wizualizacje, będące wynikiem połączenia modelu parametrycznego i działania AI oraz krytyczne wnioski i refleksje. Dane do analizy stanowią: plansze końcowe oraz studenckie refleksje dotyczące kursu, które podsumowane są w rozdziale Wnioski.

4.3. Szczegółowy opis warsztatów poświęconych zastosowaniu AI

Blok koncentrował się na powiązaniu modelowania parametrycznego z obrazowaniem generatywnym sterowanym tekstem i obrazem. Celem autora było sprawdzenie, czy narzędzia nowego typu – modele dyfuzyjne (konkretnie *Stable Diffusion*) – są użyteczne we wczesnym etapie procesu twórczego, tj. czy przyspieszają szerokie przeszukiwanie rozwiązań oraz iteracyjne doprecyzowanie intencji projektowej. Podczas pięciogodzinnych zajęć autor przeprowadził trzy ćwiczenia poprzedzone krótkim opisem sposobu korzystania ze *Stable Diffusion*, a dokładniej lokalnie uruchamianego interfejsu *WebUI*.

4.3.1. Ćwiczenie 1: Eksploracja typów i selekcja „typu”

Studenci pozyskiwali obrazy z wyszukiwarek (np. Google) i agregatorów (np. Pinterest) oraz równolegle generowali je w *Stable Diffusion* za pomocą ogólnego *promptu* przygotowanego przez prowadzącego. Zebrane warianty układane były w mozaiki (il. 2). Zbiory porządkowano w kategorie typologiczne, po czym wybierano jedną z nich i słownie definiowano „typ”: zestaw cech koniecznych oraz cech wykluczających, determinujących przynależność domu do danej kategorii. Tekstowa

1a.

1a. Fragment planszy końcowej, łączącej rezultaty ze wszystkich bloków warsztatowych. Blok 1: eksploracja i typologia. Autorki: Emilia Oniszczyk, Aleksandra Kijek. Prowadzący: mgr inż. arch.


Krzysztof Nazar

1a. An excerpt from the final board, combining the results from all workshop blocks. Block 1: exploration and typology. Authors: Emilia Oniszczyk, Aleksandra Kijek. Instructor: Krzysztof Nazar, MSc Arch.


1b. Fragment planszy końcowej, łączącej rezultaty ze wszystkich bloków warsztatowych. Blok 2: generowanie podziału funkcjonalnego. Autorki: Emilia Oniszczyk, Aleksandra Kijek. Prowadzący:

mgr inż. arch. Jakub Oszczyk

1b. An excerpt from the final board, combining the results from all workshop blocks. Block 2: generating a functional layout. Authors: Emilia Oniszcuk, Aleksandra Kijek. Instructor: Jakub Oszczyk, MSc Arch.



1 b.



[illegible]

1c. An excerpt from the final board, combining the results from all workshop blocks. Block 3: solar analysis. Authors: Emilia Oniszcuk, Aleksandra Kijek. Instructor: Krystian Kwieceński, PhD Arch.

1d. An excerpt from the final board, combining the results from all workshop blocks. Block 4: LCA and carbon footprint. Authors: Emilia Oniszczuk, Aleksandra Kijek. Instructor: Mateusz Płoszaj-Mazurek, PhD Arch.

[illegible]

2.

2. Mozaika rozwiązań wygenerowanych na podstawie promptu detached house with roof. simple architectonic ((physical model)). minimalist, simplistic, conceptual. isometric view from the top, typology. Oprac. autora

2. The mosaic of solutions generated from the following prompt: detached house with roof. simple architectonic ((physical model)). minimalist, simplistic, conceptual. isometric view from the top, typology. Prepared by the author

3. Oryginalny obraz bazowy i efekty działania preprocesorów ControlNet. Oprac. autora


3. The original baseline image and the effects of ControlNet preprocessors. Prepared by the author




3.



obraz bazowy
(widok z programu Rhinoceros)



obraz bazowy po działaniu
preprocesora ControlNet-Canny




obraz bazowy po działaniu
preprocesora ControlNet-Depth

definicja typu była wprowadzana jako prompt do Stable Diffusion i udoskonalana tak długo, aż wizualne wyniki odpowiadały intencjom studentów. W tym ćwiczeniu kontrola AI była ograniczona do metody *text-to-image* (T2I), czyli generowania obrazów na podstawie tekstu.

4.3.2. Ćwiczenie 2: Minimalny model parametryczny (Grasshopper)

Kiedy wyczerpane zostały możliwości wpłynięcia na wyniki poprzez tekst, autor zaprezentował studentom metodę kontroli *image-to-image* (I2I). Pozwala ona dodać do promptu i promptu negatywnego także obraz bazowy, który wpływa na

4.



4. Porównanie różnych metod kontroli generowania obrazu przy zastosowaniu tego samego promptu: large house with slant roof. simple architectonic ((physical model)). minimalist, simplistic, conceptual. isometric view from the top, typology. Widać, jak dodatkowe warstwy kontroli za pomocą konturów i mapy głębi pozwalają wpływać na efekty. Oprac. autora

4. Comparison of different methods of controlling image generation using the same prompt: large house with slant roof. simple architectonic ((physical model)). minimalist, simplistic, conceptual. isometric view from the top, typology. One can see how additional layers of control using contours and depth maps makes it possible to influence the effects. Prepared by the author

wynik poprzez kolory i kompozycję. Możliwe jest kontrolowanie, jak duży jest wpływ obrazu względem tekstu. Autor pokazał również bardziej selektywne metody sterowania obrazem możliwe w module ControlNet. Sygnał sterujący (*guidance*) można ograniczyć do krawędzi (Canny) lub mapy głębi (Depth) (il. 3). W tych scenariuszach obraz wejściowy jest wstępnie przetwarzany (do postaci linearnej lub mapy głębi), a powstałe reprezentacje warunkują proces odszumiania (generowania obrazu) w modelu dyfuzyjnym tak, że model „stara się” w wyniku zachować rysunek linearny bądź trójwymiarową formę obrazu bazowego. Taka forma kontroli pozwala użytkownikowi skupić się na formie i artykulacji, pozostawiając dobór detalu i materiałów modelowi dyfuzyjnemu. Zestawienie sposobów kontroli znajduje się na ilustracji 4. Przedstawia ona wyniki generowania obrazów na podstawie tego samego promptu, ale z dołożonymi różnymi warstwami kontroli (obrazami z il. 3).


Po prezentacji metod I2I oraz ControlNet autor dał studentom zadanie opracowania prostej, bryłowej reprezentacji typu domu z kluczowymi parametrami (proporcje, nachylenie dachu, relacje otworów) w środowisku VPL (Grasshopper). Autor następnie zaprezentował opracowane przez siebie rozszerzenie do Grasshoppera, które łączyło ten program ze Stable Diffusion i pozwalało wykorzystać wizualną reprezentację modelu we wspomnianych wcześniej strategiach I2I oraz ControlNet.

6. Board summarising the 'building type parametrisation' block. Atrium house. Authors: Zuzanna

parametryzacja_bryły



parametrizacja: bryła



obrazami wypełniającymi definicję wybranego typu, ilustrację modelu parametrycznego wraz z wariantami, selekcję prób wizualizacji z kolejnych iteracji oraz finalny rezultat.

5. Wyniki – analiza refleksji studentów

Autor zebrał i przeanalizował opisy procesu oraz „refleksje” na temat wykorzystania AI w projektowaniu, umieszczone przez każdy z zespołów studenckich na planszach. Poniżej znajduje się podsumowanie odpowiedzi. Jeśli w danej kategorii liczba odpowiedzi nie sumuje się do 100%, oznacza to, że nie każda grupa dała na nią odpowiedź.

Użyteczność AI w ideacji. 22/25 zespołów (88%) uznało generatywną AI za realne wsparcie w fazie koncepcji: przyspiesza powstawanie wielu wariantów i „rozszerza pole widzenia” projektanta. Wypowiedzi podkreślały szybkie testowanie odmiennych tropów i możliwość „przeskakiwania” między kierunkami bez kosztownego modelowania każdego z nich.

Warunek kompetencji projektowych. 21/25 (84%) zaznaczyło, że narzędzie nie zastępuje wiedzy i doświadczenia: bez przygotowania projektowego trudno selekcjonować sensowne rezultaty i oceniać ich wykonalność. Często powtarza się opinia o tym, że sztuczna inteligencja może zadziałać jak „akcelerator”, ale nie „automat do projektowania”.

Rola osoby bez przygotowania. 19/25 (76%) uważa, że laik może wprowadzić „uzyskać renderingi”, ale nie jest to równoważne z wykonaniem wartościowej pracy koncepcyjnej. Podkreślano potrzebę posiadania świadomości twórczej, która pozwala odróżniać dobre propozycje od słabych.

Najczęstsze trudności związane z wykorzystaniem generatywnej AI:

- *Język i precyzja promptów* – 13/25 (52%): trudność w sformułowaniu poleceń tak, by jednocześnie spełnić kilka wymagań (na przykład określoną liczbę okien, konkretny kształt); konieczne są rozbudowane negatywne prompty i wiele iteracji, aby uzyskać zamierzoną formę budynku.
- *Kontrola i powtarzalność* – 13/25 (52%): „losowość” efektów, trudność w przewidywaniu wpływu pojedynczej zmiany w ustawieniach i promptach; częsta rozbieżność między intencją a wynikiem.
- *Błędy semantyczne / geometria* – 3/25 (12%): niepoprawne dachy, „lewitujące” kondygnacje, mylne odczytywanie obrysu z obrazów bazowych; skuteczne w korekcji tych błędów było rozbudowanie promptów negatywnych oraz wzmocnienie kontroli za pomocą geometrii przez ControlNet.

Porównanie z wyszukiwarkami (Pinterest/Google/IG). 11/25 (44%) zespołów wprost porównało oba sposoby pracy: wyszukiwarki podają „cudze przykłady”, a generatywna AI pozwala wytwarzać i prowadzić przegląd rozwiązań zgodnie z własną wizją. Równocześnie podkreślano, że wyszukiwarki są lepsze do weryfikacji rzeczywistych odniesień (materiały, detale, konstrukcja) – czego w procesie

generatywnym często brakuje, bo modele AI potrafią „zmyślać” nierealistyczne warianty i ukrywają źródła pochodzenia wyników.

Wprowadzenie AI do własnego warsztatu projektowego. Deklaracje studentów odnośnie chęci korzystania z AI dzielą się niemal po równo: 12/25 (48%) odpowiedziało „tak / AI powinna stanowić integralną część zestawu narzędzi”, 11/25 (44%) dopuściło stosowanie „warunkowo / nie powszechnie” (wyłącznie jako dodatek, zależnie od kontekstu i etapu pracy). 8/25 (32%) zespołów zaznaczyło, że istotne jest posiadanie i rozwijanie kompetencji w zakresie wykorzystania AI w projektowaniu architektonicznym. Jednoznaczny sprzeciw wobec upowszechnienia tej technologii wyraziło 3/25 (12%) zespołów.

Konieczność wprowadzenia wizualnych elementów kontroli. 11/25 (44%) zespołów raportowało wprowadzanie parametrycznego modelu 3D jako podpowiedzi do generatora jako niezbędne do uzyskania założonej bryły (np. wyraźna płaszczyzna tarasu, kontury atrium, dokładna definicja połączenia dachu).

Wybór przykładowych wypowiedzi studentów – uczestników kursu znajduje się w załączniku nr 2 do artykułu.

6. Dyskusja

W przeprowadzonych przez autora ćwiczeniach połączenie prostego modelu parametrycznego (Grasshopper) z generowaniem obrazów w Stable Diffusion sterowanym przez ControlNet oraz praca w pętli *human-in-the-loop* pomogło studentom szybciej i czytelniej przetestować „typy” budynku, a następnie doprowadzić jeden z nich do spójnej koncepcji. Kluczowy wniosek jest taki, że dodanie warunków geometrycznych (prosta wizualizacja brył) do tekstowych promptów znacznie zwiększa kontrolę nad modelami dyfuzyjnymi – do poziomu użytecznego w projektowaniu. Oznacza to, że AI ujawnia potencjał dopiero, kiedy jej użytkownik ma konkretne intencje oraz przynajmniej podstawowe umiejętności wyrażenia ich w sposób wizualny (np. poprzez szkic lub model 3D). Zastosowanie rozszerzenia programu Grasshopper, które automatycznie przenosi widok do Stable Diffusion wraz z możliwościami modelowania parametrycznego sprawiło, że poszukiwanie rozwiązań było intuicyjne i szybkie.

Uzyskane w przeprowadzonych przez autora ćwiczeniach rezultaty są spójne z wnioskami literatury wskazującej, że narzędzia AI powinny wzmacniać kreatywność i rozwiązywanie problemów, a nie zastępować autorstwo. Włączenie prostego modelu parametrycznego (Grasshopper) jako warstwy sterującej oraz praca w pętli *human-in-the-loop* uporządkowały eksplorację „typów” i przyspieszyły przejście od szerokiego przeglądu wariantów do spójnej koncepcji. W tym sensie nasze podejście wpisuje się w rekomendację, by w studiach projektowych uczyć zarówno generowania koncepcji z pomocą AI, jak i kompetencji projektowania całego procesu generatywnego, utrzymując decyzyjność po stronie człowieka¹⁸. Istotna okazuje się też

¹⁸ M. El Moussaoui, K. Krois, *Architectural Pedagogy in the Age of AI: The Transformation of a Domain*, w: *School of Architecture(s) – New Frontiers of Architectural Education. EAAE Annual Conference – Turin 2023*, red. M. Barosio, E. Vigliocco, S. Gomes, Cham 2025, s. 87–93.

umiejętność nazywania intencji projektowych: celu, ograniczeń i cech pożądanego rozwiązania. Badania nad użyciem AI generującej obrazy na podstawie tekstu pokazują, że „pisanie do narzędzia” może być kompetencją samą w sobie – dobór słów i struktura promptu istotnie wpływają na rezultat, a dłuższe, ustrukturyzowane opisy częściej prowadzą do wyników wyższej jakości¹⁹. Innymi słowy, jakość obrazu bywa pochodną jakości opisu. Jest to zgodne z tendencją rozwoju interfejsów, które coraz częściej opierają się na języku naturalnym. To argument, by w dydaktyce celowo ćwiczyć „mówienie i pisanie o architekturze” jako część procesu projektowego, a nie jedynie komunikację końcową.

Zaskoczeniem dla autora była rozbieżność między wysoką oceną przydatności AI do ideacji a umiarkowaną deklaracją trwałego włączenia tych narzędzi do własnego warsztatu – część studentów wskazywała na „losowość” i problem powtarzalności. Możliwym wyjaśnieniem jest bariera sprzętowa: praca na słabych kartach graficznych, w jakie wyposażone są komputery w pracowni, do której mieliśmy dostęp, znacznie wydłużyła czas każdej iteracji i zniechęcała do eksperymentowania i dostosowywania parametrów.

Z pedagogicznego punktu widzenia wartościowe wydaje się „oswojenie” studentów z nieznaną technologią, wobec której narastają liczne obawy. Do jednej tych obaw należy bez wątpienia strach przed zastąpieniem – w tym przypadku architektów – przez sztuczną inteligencję. Zebrane przez nas refleksje jasno wskazują, że po zapoznaniu się z ograniczeniami modeli AI generujących obrazy studenci nabrali sceptycyzmu wobec tego sposobu pracy. W przyszłych edycjach kursu warto byłoby przeprowadzić ankiety również przed zajęciami i sprawdzić, czy stosunek studentów do narzędzi opartych na AI uległ zmianie po warsztatach. Obiecujące wydaje się także porównanie dwóch sposobów pracy przy głównym projekcie semestralnym: udostępnienie części studentów narzędzi takich jak modele dyfuzyjne na etapie ideacji, a na koniec semestru porównanie z grupą kontrolną, która nie miała takiego dostępu. Dałoby to podstawę do oceny, czy korzyści z wykorzystania AI są realne.

Na koniec warto zaznaczyć, że podstawowe wykorzystanie generatywnej AI, tzn. wyłącznie tworzenie obrazów poprzez wpisywanie promptów do ogólnodostępnych narzędzi, nie przystaje do profesjonalnej praktyki w dużych biurach projektowych. Firmy wiodące we wdrożeniach innowacyjnych narzędzi opracowują własne, pełne schematy pracy oparte na autorskich narzędziach i własnych serwerach. Przykładowo Foster + Partners wdrożyli firmową wtyczkę uruchamiającą modele dyfuzyjne bezpośrednio z Rhinoceros (w tym generowanie obrazów na bazie istniejącej geometrii), a do ideacji używają lokalnie uruchamianego Stable Diffusion, żeby chronić dane i własność intelektualną²⁰ (nawiasem mówiąc, jest to bardzo podobne do metod zaprezentowanych w tym artykule). Heatherwick Studio deklaruje przejście od gotowych rozwiązań do własnych modeli trenowanych na wewnętrznych danych

¹⁹ V. Paananen, J. Oppenlaender, A. Visuri, *Using text-to-image generation for architectural design ideation*, „International Journal of Architectural Computing”, t. 22, 2023, nr 3, s. 458–474.

²⁰ Foster + Partners, *Design, Technology, and the Team Between* (+Plus Journal), <https://www.fosterandpartners.com/insights/plus-journal/design-technology-and-the-team-between> (dostęp 31.10.2025).

i narzędzia do generowania obrazów utrzymywanego na lokalnym serwerze²¹. Wynika to z obaw o własność intelektualną, ale też jakość i oryginalność rozwiązań. Zaha Hadid Architects rozwijają oryginalne rozwiązania oparte na AI od początku ich popularyzacji od 2021 roku. Próbowali trenowania modeli na swoich danych, wykorzystując je przede wszystkim do przyspieszania iteracji pracy nad projektem, najczęściej poprzez wizualizacje. Świadomi ograniczeń narzędzi ogólnego przeznaczenia, szczególnie w zakresie „rozumienia” tektoniki i konstrukcji, pracują nad pomostem 2D–3D i integracją różnych programów do modelowania. Ma to służyć rozszerzeniu „kompetencji” AI o tworzenie użytecznej trójwymiarowej geometrii zgodnie z logiką konstrukcyjną²².

7. Podsumowanie

Generatywna AI w ćwiczeniach przeprowadzonych przez autora wyraźnie poszerzyła przestrzeń poszukiwań i przyspieszyła ideację, ale nie zastąpiła kompetencji projektowych ani sądu projektanta. W niektórych przypadkach sprawiała wręcz wrażenie utrudnienia uzyskania rezultatu, który dana grupa studencka była w stanie sobie wyobrazić, a nawet samodzielnie wymodelować. Najlepsze rezultaty dawało sprzężenie modelowania parametrycznego (Grasshopper) z obrazowaniem generatywnym przez *image-to-image*/ControlNet (zwłaszcza Canny i Depth): studenci utrzymywali kontrolę nad geometrią i częściej uzyskiwali zgodność wyniku z intencją, odkrywając proste reguły mapowania (np. kolor-beżowy → materiał-drewno). Główną barierą była kontrolowalność i powtarzalność – pojawiał się „dryf” stylistyczny i niespójność lub niepoprawność geometrii. Istotnie ograniczał nas dostępny sprzęt komputerowy (karty graficzne o minimalnej wymaganej specyfikacji), wydłużając iteracje. Dostęp do mocniejszych zasobów znacząco podniósłby wartość dydaktyczną oraz usunąłby możliwy negatywny wpływ na ocenę narzędzia przez studentów. Standaryzacja procesu (wspólne prompty, ograniczony zestaw modeli i kanałów ControlNet) umożliwiła porównywalność wyników i przeprowadzenie warsztatów w krótkim czasie, co jest szczególnie istotne z punktu widzenia przeładowanych programów nauczania. Wnioski, które wyciągnęliśmy, dotyczą jednego rocznika i ściśle ustawionego środowiska, więc należy je uogólniać ostrożnie. Podsumowując: największą wartość przynosi projektowanie wspomagane – człowiek + AI – wprowadzane w programie studiów wtedy, gdy studenci potrafią już krytycznie ocenić wyniki i dodawać własne mechanizmy kontroli, a stopniowe omawianie technik (T2I → I2I → model parametryczny → ControlNet) pozwala dobrze zrozumieć możliwości i ograniczenia sztucznej inteligencji.

²¹ D. Chevin, *How Heatherwick humanises buildings... with technology*, „Construction Management”, 06.12.2024, <https://constructionmanagement.co.uk/how-heatherwick-humanises-buildings-with-technology/> (dostęp 31.10.2025).

²² J. Bell, *AI in architecture: Zaha Hadid Architects on its pioneering use and collaborating with NVIDIA*, „Wallpaper*”, <https://www.wallpaper.com/architecture/zaha-hadid-architects-nvidia-ai-in-architecture> (dostęp 31.10.2025).

Załącznik nr 1. Konfiguracja oprogramowania

Poniżej znajduje się opis konfiguracji, którą autor wybrał do realizacji zajęć:

- Stable Diffusion WebUI 1.6.0 (AUTOMATIC1111) uruchamiane z włączonym API (--api) oraz optymalizacjami pamięci --xformers i --medvram (wynikającymi z koniecznego kompromisu wydajności na słabszych kartach graficznych zainstalowanych w pracowni). Parametry te są oficjalnie dokumentowane w projekcie WebUI.
- Rozszerzenie *ControlNet for Stable Diffusion WebUI*. Z modeli ControlNet autor wykorzystał Canny (detekcja krawędzi) i Depth-Midas (mapa głębi), które w trakcie własnych testów przed uruchomieniem kursu okazały się najbardziej użyteczne w kontrolowaniu modelu dyfuzyjnego poprzez renderingu prostej parametrycznej bryły.
- Rhinoceros 7 + Grasshopper wraz z autorskim rozszerzeniem do komunikacji z API WebUI. Przygotowane przez autora rozszerzenie pozwalało na skonfigurowanie pełnego polecenia do Stable Diffusion i automatyzowało przekazanie obecnego widoku z programu Rhinoceros do modułu ControlNet. Znacznie ułatwiło to generowanie kolejnych iteracji oraz ich dokumentacji.
- Modele bazowe (checkpoints) do Stable Diffusion: realisticVisionV60B1_v51VAE, deliberate_v6, reliberate_v3 (dystrybuowane przez huggingface; dobrane po testach jakości).
- LoRA (Low-Rank Adaptation) – lekkie moduły stylizujące, narzucające estetykę modeli architektonicznych. Autor celowo ograniczył fotorealizm, by skupić uwagę studentów na bryle i typie. LoRA, które zastosowaliśmy, nie są już dostępne w czasie pisania artykułu.

Załącznik nr 2. Przykładowe wypowiedzi studentów – uczestników kursu (wybór)

Użyteczność w projektowaniu:

„Generatywna sztuczna inteligencja jest bardzo przydatna podczas tworzenia koncepcji. Pozwala szybko przetestować kilkanaście–kilkadziesiąt różnych rozwiązań czy wariantów tego samego pomysłu.”

„Generatywna sztuczna inteligencja pomaga w pracy koncepcyjnej, dając możliwość stworzenia wielu wersji z różnymi ustawieniami, pokazując przykłady, na które sami byśmy nie wpadli.”

„Generatywna sztuczna inteligencja, zwłaszcza w Grasshopper i Stable Diffusion, rewolucjonizuje moją koncepcyjną pracę architektoniczną.”

„Sztuczna inteligencja pozwala na szybkie generowanie rozwiązań wizualnych, które mogą proponować rozwiązania (np. materiałowe, bryłowe), na które twórca sam by nie wpadł.”

Warunek doświadczenia i umiejętności:

„Choć narzędzie to może być inspirujące, doświadczenie projektowe nadal odgrywa kluczową rolę w skutecznym wykorzystaniu generatywnej sztucznej inteligencji.”

„Do architekta należy przefiltrowanie, które warianty są możliwe do realizacji, a które tylko ładnym obrazem, bez realnych szans na zbudowanie.”

„Do projektowania rozwiązań, które będą nie tylko estetyczne, ale też funkcjonalne, niezbędne jest podłoże w postaci nauki projektowania.”

„Bez wiedzy dotyczącej projektowania nie można by było odróżnić dobrych podpowiedzi AI od złych, a sam proces bez własnych przemyśleń mógłby okazać się płytki.”

Trudności z kontrolą:

„Prompt musi być bardzo precyzyjny, a czasem nawet przy wielu próbach nie uzyskujemy satysfakcjonujących wyników.”

„Barierą w pracy z AI wydaje nam się ograniczenie kontroli nad powstającymi wariantami – przy generowaniu kolejnych iteracji trudno precyzyjnie zmieniać dane cechy bez wpływania na pozostałe.”

„Niestety często trudno jest przekazać sztucznej inteligencji, co dokładnie chcemy otrzymać na zdjęciu, co jest największą trudnością w korzystaniu z niej.”

„Dużą trudność może sprawiać dobór odpowiednich promptów. Bez sugestii np. w postaci grafiki, może być trudno osiągnąć zamierzony efekt.”

Bibliografia

Alymani A.A.A., *Integrating Artificial Intelligence Rendering Tools in Design: Integrating AI as teaching methods in architectural education*, w: *Data-Driven Intelligence. Proceedings of the 42nd Conference on Education and Research in Computer Aided Architectural Design in Europe (eCAADe 2024)*, t. 2, red. O. Kontovourkis, M. C. Phocas, G. Wurzer, Nicosia 2024, DOI: 10.52842/conf.ecaade.2024.2.629

Bell J., *AI in architecture: Zaha Hadid Architects on its pioneering use and collaborating with NVIDIA*, „Wallpaper*”, 13.12.2024, <https://www.wallpaper.com/architecture/zaha-hadid-architects-nvidia-ai-in-architecture>

Bernstein P., *Machine Learning: Architecture in the Age of Artificial Intelligence*, London 2022, DOI: 10.4324/9781003297192

Bolojan D., *Creative AI: Augmenting Design Potency*, „Architectural Design”, 2022, nr 92(3), DOI: 10.1002/ad.2809

Carpó M., *The Digital Turn in Architecture 1992–2012*, Chichester 2012

Carpó M., *The Second Digital Turn: Design Beyond Intelligence*, Cambridge MA 2017

Chevin D., *How Heatherwick humanises buildings... with technology*, „Construction Management”, 06.12.2024, <https://constructionmanagement.co.uk/how-heatherwick-humanises-buildings-with-technology/>

Cudzik J., Nyka L., Szczepański J., *Artificial intelligence in architectural education – green campus development research*, „Global Journal of Engineering Education”, 2024, nr 26(1), DOI: 10.1011/gleej1050

El Moussaoui M., Krois K., *Architectural Pedagogy in the Age of AI: The Transformation of a Domain*, w: *School of Architecture(s) – New Frontiers of Architectural Education. EAAE AC 2023*, red. M. Barosio, E. Vigliocco, S. Gomes, Cham 2025, DOI: 10.1007/978 3 031 71959 2_11

Foster + Partners, *Design, Technology, and the Team Between*, „+Plus Journal”, <https://www.fosterandpartners.com/insights/plus-journal/design-technology-and-the-team-between>

- Horvath A.-S., Poulou P., *AI for conceptual architecture: Reflections on designing with text-to-text, text-to-image, and image-to-image generators*, „Frontiers of Architectural Research”, t. 13, 2024, nr 3, DOI: 10.1016/j.foar.2024.02.006
- Jin S., Tu H., Li J., Fang Y., Qu Z., Xu F., Liu K., Lin Y., *Enhancing Architectural Education through Artificial Intelligence: A Case Study of an AI-Assisted Architectural Programming and Design Course*, „Buildings”, t. 14, 2024, nr 6, DOI: 10.3390/buildings14061613
- Leach N., *Architecture in the Age of Artificial Intelligence: An Introduction to AI for Architects*, London–New York 2022, DOI: 10.36253/techne-14769
- Oxman R., *Thinking difference: Theories and models of parametric design thinking*, „Design Studies”, 2017, t. 52, DOI:10.1016/j.destud.2017.06.001
- Özorhon G., Nitelik Gelirli D., Lekesiz G., Müezzinoğlu C., *AI-assisted architectural design studio (AI-a-ADS): How artificial intelligence join the architectural design studio?*, „International Journal of Technology and Design Education”, t. 35, 2025, nr 5, DOI: 10.1007/s10798-025-09975-0
- Paananen V., Oppenlaender J., Visuri A., *Using text-to-image generation for architectural design ideation*, „International Journal of Architectural Computing”, t. 22, 2023, nr 3, DOI: 10.1177/14780771231222783
- Ploennigs J., Berger M., *AI art in architecture*, „AI in Civil Engineering”, t. 2, 2023, nr 1, art. 8, DOI: 10.1007/s43503-023-00018-y
- Royal Institute of British Architects, *RIBA AI Report 2024*, <https://www.architecture.com/knowledge-and-resources/resources-landing-page/riba-ai-report-2024>
- Slyk J., Ostrowska-Wawryniuk K., Strzała M., *Form Follows Parameter: Algorithmic Thinking Oriented Course for Early Stage Architectural Education*, „Nexus Network Journal”, t. 24, 2022, nr 2, DOI: 10.1007/s00004-022-00603-1
- Yiannoudes S., *Shaping Architecture with Generative Artificial Intelligence: Deep Learning Models in Architectural Design Workflow*, „Architecture”, t. 5, 2025, nr 4, DOI: 10.3390/architecture5040094
- Yuan P.F., *Toward a generative AI-augmented design era*, „Architectural Intelligence” 2023, t. 2, 2023, nr 1, art. 16, DOI: 10.1007/s44223-023-00038-9
- Zhang H., Zhang R., *Generative artificial intelligence (AI) in built environment design and planning – A state-of-the-art review*, „Progress in Engineering Science”, t. 2, 2025, nr 1

Generative artificial intelligence in architectural education: a study of the use of diffusion models in conceptual design

Abstract

This article presents a study of the application of generative artificial intelligence (AI) in the early architectural design phase. Its purpose is to verify whether these tools speed up the development of a concept and how to increase control through simple parametric models and a clearly defined decision loop including a human. The study was based on a course taught at the Faculty of Architecture of the Warsaw University of Technology by a team of teachers from the Chair of Architectural Design and the Department of Pro-Environmental Design. The course was attended by 62 students in 25 teams. The course was divided into four blocks (type exploration and visualisation, automation of functional layout generation, insulation analysis and life cycle assessment) – the first of these is described in detail in this article. The course combined parametric modelling with a text- and image-driven image generator. The results of student surveys conducted at the end of the course indicate that AI was useful at the concept stage for 88% of them; the main barriers were limited predictability, repeatability and hardware requirements. The best results were produced by a combination of a clearly defined designer's intention with a simple 3D model and a critical selection of results. The course authors recommend integrating AI into the curriculum as a way to learn to work with the

process (formulating criteria, controlling the course, evaluating the results), rather than only operating result-focused tools.

Keywords generative design | generative artificial intelligence | parametric modelling | diffusion models | design didactics | architectural visualisation

1. Research problem and scope of the article

The article describes a portion of an academic course that focused on the use of artificial intelligence (AI) at the early stage of architectural design. The purpose of the study was to determine whether artificial intelligence has the potential to facilitate or improve the performance of conceptual work, and how its performance can be improved by using a parametric model as an additional layer of control.

The first section presents the current trends in design and teaching practice that point to the increasingly common use of AI-based tools. The description ends with a justification for addressing this topic. Previous examples of the introduction of artificial intelligence in courses in architectural programmes are then outlined. The next part is a description of the unique course curriculum, which we implemented in the team composed of Krystian Kwieciński, PhD Arch., Szymon Płoszaj-Mazurek, PhD Arch., Krzysztof Nazar, MSc Arch., and Jakub Oszczyk, MSc Arch., during

the seventh semester of the long-cycle programme of studies in architecture at the Faculty of Architecture of the Warsaw University of Technology. Subsequent chapters focus on the software configuration required to replicate the classes, a description of the design tasks set for the students and the content of the surveys that formed the basis for the assessment of the implementation. The article ends with a presentation of the results of the course, a discussion and an assessment of the relevance of teaching how to use artificial intelligence in courses during architectural studies.

2. Introduction

Recent years have been a time of 'AI-assisted design' in architecture. Artificial intelligence does not replace the designer, but expands the designer's field of vision – allowing him or her to verify various creative pathways more quickly and thus make decisions more efficiently. Diffusion models (AI image generators) should be considered as a partner at the stage of first sketches and not as the 'author' of the design, since the assessment of and responsibility for the choices remain with the human¹. Since we are increasingly handing over part of the creative work to machines, it makes sense to move away from the 'tool versus creator' opposition and think about collaboration and co-authorship. This understanding of support is described by Philip F. Yuan, among others: machines enhance the perception, thinking and imagination of architects rather than replacing them².

The 2024 report of the Royal Institute of British Architects (RIBA), based on a survey of its members, shows a growing interest in the use of AI in architecture combined with cautious implementation: 41% of studios use AI at least occasionally, although only 2% use it for every project

(59% never do it)³. Among those using AI, 43% already report improvements in the efficiency of the design process. Over the next 2 years, expectations of wider implementation prevail: 54% expect to use AI in their own studio and 57% expect efficiency improvements as a result of technology developments. At the same time, only 20% of studios invest in R&D work on AI (implementations and suitability studies), which explains why it is important in education to teach procedures, evaluation criteria and documentation for working with off-the-shelf tools that operate as *black boxes* (when the mechanisms of operation are not exactly known).

Phil Bernstein argues that the integration of artificial intelligence into the work of professional architects is not an externally imposed revolution, but the next stage of development after CAD, BIM and parametric modelling. AI is starting to provide support in the daily design routine: not only by 'drawing' and modelling, but also by analysis and predicting the consequences of design decisions. In the preparation of documentation, AI provides automation and less costly corrections at later stages of the design⁴. This shift will be increasingly felt in practice: systems based on machine learning are meant to extend our competences – not to replace architects, but they influence the way we work by reorganising the division of roles⁵. For education, this is a hint to avoid the mistake made when teaching BIM modelling methods, which were often reduced to the use of software, without including the way of thinking and real processes in design studios. AI needs to be integrated into the curriculum, not as another software-oriented course, but as an exercise familiarising students with the new roles an architect

¹ D. Bolojan, *Creative AI: Augmenting Design Potency*, "Architectural Design", 2022, no. 92(3), pp. 22–27.

² P. F. Yuan, *Toward a generative AI-augmented design era*, "Architectural Intelligence", vol. 2, 2023, no. 1, art. 16.

³ Royal Institute of British Architects, *RIBA AI Report 2024*, <https://www.architecture.com/knowledge-and-resources/resources-landing-page/riba-ai-report-2024> (accessed on 31 October 2025).

⁴ P. Bernstein, *Machine Learning: Architecture in the Age of Artificial Intelligence*, London 2022, pp. 9–10.

⁵ Op. cit., p. 103.

has to play. Students should be taught how to work with large data sets, define clear and measurable criteria for evaluating generated works, combine parametric models with analysis and evaluation of results, and ensure human-algorithm collaboration in real design scenarios⁶. The broader context of these transformations is set by the discourse of *digital turns* in architecture – from the computerisation of representation and production to the tools that take over computation, thinking and inference – synthetically addressed in the work of Mario Carpo and Neil Leach⁷.

In the last ten years, interest in AI in the design of buildings and cities has accelerated strongly, as shown in a review article by Hao-lan Zhang and Ruichuan Zhang⁸. Until 2018, the number of publications on AI in architectural and urban design was rather moderate, and since 2019 there has been a clear increase in that number. The keyword map also shows a shift in emphasis: the discourse has shifted from *computer-aided design* and *topology optimisation* towards artificial intelligence methods such as *deep learning* and *generative adversarial networks*. The authors of the review collected a total of 179 papers from the last decade, organising them according to three fields of application – site development (urban planning), interiors and façades – and three method classes – expert systems, optimisation and machine learning. The authors demonstrate that AI today affects the full spectrum of tasks: from land development planning to façade details. This gives a picture of a rapidly growing and increasingly standardised field of research into AI in architectural and urban design. Another systematic

review (from 2015–2025) by Socrates Yiannoudes shows that 85% of studied generative AI solutions in architecture end up with raster images or un-editable geometry, and only 15% provide models that can be used in CAD or BIM software⁹. At the same time, 69% of the methods are limited to conceptual work. This gives a picture of constraints and industry trends.

The choice of topic and the purpose of the article stem from two considerations. Firstly, there is a need for an accessible and concise didactic scenario that will teach students to control diffusion models using simple explicit conditions (verbal definitions supported by geometrical constraints). The aim is to familiarise them with a tool around which myths and fears about the future of the profession are growing. The second consideration is the need to embed AI-based tools in the logic of algorithmic thinking, where the rules of conduct and evaluation criteria are as important as the results. In addition to teaching how to use the tool, it is essential to start a discussion on the changes in design practice that will result from the technological developments.

3. Research background

Research into generative and algorithmic design in architecture has a long history that goes far beyond the recent wave of popularity of artificial intelligence. In *parametric design thinking* (PDT), a design is described as a scheme of relationships (parameters and dependencies) that generates whole families of solutions and allows fast, reversible revisions, usually in VPL (*visual programming language*) interfaces combining code and geometry (e.g. Rhinoceros+Grasshopper). Rivka Oxman organises these practices and decision-making loops into the R-E-P-G (*representation-evaluation-performance-generation*) flow model: a rule change immediately restructures the model and allows the

⁶ Op. cit., pp. 105–106.

⁷ M. Carpo, *The Digital Turn in Architecture 1992–2012*, Chichester 2012, pp. 8–14; idem, *The Second Digital Turn: Design Beyond Intelligence*, Cambridge, MA 2017, pp. 1–8; N. Leach, *Architecture in the Age of Artificial Intelligence: An Introduction to AI for Architects*, London–New York 2022, chapters 5–7.

⁸ H. Zhang, R. Zhang, *Generative artificial intelligence (AI) in built environment design and planning – A state-of-the-art review*, “Progress in Engineering Science”, vol. 2, 2025, no. 1.

⁹ S. Yiannoudes, *Shaping Architecture with Generative Artificial Intelligence: Deep Learning Models in Architectural Design Workflow*, “Architecture”, vol. 5, 2025, no. 4, pp. 1–24.

transition to the evaluation. Equally importantly, parametric design interfaces make generative rules visible and editable in real time. This is why parametrics naturally teaches how to work on the design space rather than on one 'final' result (generative design vs. direct design)¹⁰.

At the Faculty of Architecture of the Warsaw University of Technology, a coherent pedagogy for parametric modelling was developed, as described by Jan Słyk, Karolina Ostrowska-Wawryniuk and Marcin Strzała. The class model developed there proposes three phases: analytical (reduction of the design case to a step-by-step algorithm), application (implementation of the algorithm using VPL – Grasshopper) and exploratory (systematic search of variants of the parametric model). An important exercise is the 'control group': one team of students reconstructs a design case solely from instructions written by another team. This swapping of roles can reveal ambiguities and necessitates the use of precise wording. Such experience proves valuable when working with AI, as it improves the ability to anticipate that written commands may be misinterpreted. Importantly, the authors report a marked increase in course effectiveness (over 50% more passing grades) when the focus of the course shifts from 'tool operation' to algorithmic thinking and informed definition of parameters¹¹. This is in line with Bernstein's calls for a 'pedagogy of new tools' described in the introduction.

In recent years, computational design has increasingly addressed the issue of generative imaging with AI. Joern Ploennigs and Markus Berger compare the Midjourney, DALL-E 2 and Stable Diffusion image generation systems, showing that iterative work (on average at least four 'steps' to a 'good' image), masking operations (*in-*

out-painting) and adjusting settings (in particular the weights of individual control layers) become a practical 'control language' – the equivalent of parameters in a geometric model. The façade development scheme they present combines initial ideation in Midjourney, frame widening (*out-painting*) and substitution (*inpainting*) in DALL-E 2 and refining in Stable Diffusion. The authors note the limitations of AI tools in the semantic layer – generative plans and sections – lack the necessary precision and unambiguity¹².

The 'Green campus' teaching experiment described by Lucyna Nyka, Jan Cudzik and Jakub Szczepański documents the impact of AI imaging in *research-by-design studio*. In a two-year comparative arrangement (one year without AI versus one year with AI), three patterns of work were identified: a. semi-traditional (AI only as inspiration), b. hybrid (using generated images in design work) and c. hybrid-interactive (influencing generated images through additional layers of control), with the latter path yielding the best results according to the authors. The authors report speeding up the creation of conceptual material (inspiration boards – *mood boards*, solution variants) and opening up 'thinking paths' in the first weeks of the course; in parallel, they point out the difficulty of accepting the final design concepts given the 'ease' of their generation and argue for a shift in the assessment of students' work from the final outcome to the competence in the design and control of processes¹³.

An interesting reference is the case study of a course, in which AI is integrated into nine weeks of design – from queries and functional programming (using large language models – LLMs) to conceptualisation and refinement of visualisation (using diffusion models). Shitao Jin et al. show

¹⁰ R. Oxman, *Thinking difference: Theories and models of parametric design thinking*, "Design Studies", 2017, vol. 52, pp. 4–39.

¹¹ J. Słyk, K. Ostrowska-Wawryniuk, M. Strzała, *Form Follows Parameter: Algorithmic Thinking Oriented Course for Early Stage Architectural Education*, "Nexus Network Journal", vol. 24, 2022, no. 2, pp. 503–522.

¹² J. Ploennigs, M. Berger, *AI art in architecture*, "AI in Civil Engineering", vol. 2, 2023, no. 1, art. 8.

¹³ J. Cudzik, L. Nyka, J. Szczepański, *Artificial intelligence in architectural education – green campus development research*, "Global Journal of Engineering Education", 2024, no. 26(1), pp. 20–25.

that such integration has a positive impact on the design process: the average self-assessment of 'overall effectiveness' increased from 2.71 to 4.04 out of a possible 5. Students most often emphasised two positive factors: AI-based tools stimulate innovative thinking and realistically increase productivity. At the same time, they rated AI's support in organising information and programming decisions (working on text) higher than the support in the synthesis of form itself (images), which was linked to the limited controllability of diffusion models. The authors of the article recommend combining image generation with a parametric basis (Rhino+Grasshopper or BIM software). This can inspire a clear division in teaching practice: language models used for design programme development and requirements analysis, image generators for a quick broad overview of inspiration and the parametric model as a control layer. The results of the research indicate that diffusion models are most useful at the early design stage¹⁴.

The workshop proposal 'AI-assisted architectural design studio' (AI-a-ADS) also locates diffusion models at the beginning of design work – as a catalyst for ideas. In a three-part course, the authors planned in sequence: 1) reproducing keywords based on sketches and models made by students; 2) entering keywords into a prompt template in the Midjourney tool in order to generate a visualisation of a building's cross-section; 3) using the cross-section model to make final adjustments to the result (*blend images*). The results of the course end surveys indicated that students appreciated the opportunity to learn about AI-based tools, while also stating that the results of their operation were generally not useful and were not used in their designs¹⁵.

Also worth noting is a study that systematically introduces an AI rendering engine into the workflow of a design studio. In a 'micro-house' course, the second-year students progressed from classical analysis of the site and precedents, through 2D drawings, to 3D capacity studies, and then combined their own model with the AI tool in three steps: 1) only volumes without materials; 2) generation of variants and hints based on the 3D scene; 3) final visualisation to evaluate the materials and the detail. The sample comprised eight designs; the evaluation was carried out in terms of, among other things, creativity, functionality, feasibility and compliance with the programme. Abdulrahman Ahmed A. Alymani reports improvements in the quality and complexity of solutions over the course of a semester (in both quantitative and qualitative data), as well as a reduction in task completion time. The mechanism of action has been described as repetitive prompt-image-evaluation loops. The AI visualisation enabled rapid testing of material and lighting variants and iterative verification of solutions. In the description of the case studies, there are adjustments that resulted from the extensive review, including adjusting the geometry and circulation paths to the topography of the site, changing circulation layouts or introducing a particular volumetric articulations or a particular material¹⁶.

Against the backdrop of the widespread use of off-the-shelf AI models, it is worth noting a parallel path of experimentation that requires greater technical proficiency: training tools on collections of individually selected and labelled images. This is to ensure, on the one hand, that the results are more in line with the intentions and, on the other hand, that there is a certain amount of uniqueness in the solutions.

¹⁴ S. Jin et al., *Enhancing Architectural Education through Artificial Intelligence: A Case Study of an AI-Assisted Architectural Programming and Design Course*, "Buildings", vol. 14, 2024, no. 6, pp. 14–16.

¹⁵ G. Özorhon et al., *AI-assisted architectural design studio (AI-a-ADS): How artificial intelligence join the architectural design studio?*, "International Journal of Technology and Design Education", vol. 35, 2025, no. 5, pp. 1999–2023.

¹⁶ A.A.A. Alymani, *Integrating Artificial Intelligence Rendering Tools in Design: Integrating AI as teaching methods in architectural education*, in: *Data-Driven Intelligence. Proceedings of the 42nd Conference on Education and Research in Computer Aided Architectural Design in Europe (eCAADe 2024)*, vol. 2, eds. O. Kontovourkis, M. C. Phocas, G. Wurzer, Nicosia 2024, pp. 629–638.

Anca-Simona Horvath and Panagiota Pouliou describe the process of training generative models based on texts from Architectural Design and the eVolo competition, as well as 480 eVolo competition boards¹⁷. The aim was to generate a complete competition entry. The authors showed that the direct influence on the datasets used to train the models gave them a sense of greater agency over the outcome. However, this came at a cost: machine learning algorithms require very large sets of images, which additionally need to be described (labelled) correctly. Time devoted to this task could be spent on traditional creative work. In their case, the design process shifted from sketching and team discussions to working with programming languages and datasets. On the other hand, the process of organising the data on 'what has been done before' was very instructive and made it possible to observe patterns of successful works from previous editions. The authors even point out that building a machine learning database could itself be a good tool for teaching art and design history and theory, as it redirects attention to looking for hidden relationships in seemingly unrelated content.

The context presented indicates a consensus on three common elements: 1) the productive role of broad search (diffusion models) defined by clear input conditions; 2) the need for additional visual control layers, e.g. via an author's sketch or parametric model; 3) the requirement for human participation as a critic and moderator of the generative process (*human-in-the-loop*, HIL). The exercise presented in this article – which combines the Stable Diffusion model with a simple parametric model in Rhinoceros+Grasshopper and an explicitly defined evaluation loop – addresses these three elements and attempts to systematise the way of incorporating generative artificial intelligence into computational design education.

¹⁷ A.-S. Horvath, P. Pouliou, *AI for conceptual architecture: Reflections on designing with text-to-text, text-to-image, and image-to-image generators*, "Frontiers of Architectural Research", vol. 13, 2024, no. 3, pp. 593–612.

4. Research method

The course analysed below lasted 25 teaching hours and involved four student groups. The topic of the course was to design a single-family house in such a way as to maximise the use of the available digital generative tools and reduce one's own work to the role of a reviewer of the processes carried out by the computer. We asked the students a speculative question: 'Are we at a stage of technological development where computers, and especially artificial intelligence, can replace the designer?' We divided the course into four five-hour workshop blocks: 1. type exploration, parametrisation of building types and AI-based image generation; 2. automation of functional layout generation using optimisation algorithms; 3. insolation analyses; 4. environmental life cycle assessment – LCA. The final five-hour block focused on presentation of the works and discussion. A detailed description of the blocks can be found in the next chapter. As mentioned earlier, we intentionally limited the nature of the students' participation in the design process to a *human-in-the-loop* role: they acted as facilitators and critics of the automated processes we prepared as the lesson plans. Crucial to the research was the collection of the results of the students' work after each block, as well as their reflections on the usefulness of the generative methods used. Sixty-two students participated in the course, forming 25 working groups of 2–3 people each. This article describes the first workshop block in particular and discusses its results.

4.1. Description of the individual workshop blocks

Block 01 (exploration and typology) was conducted by the author of the article. The workshop covered the parametrisation of a single-family house volume and the methods for searching the solution space using parametric modelling (Rhinoceros+Grasshopper) and generative imaging (Stable Diffusion). The participants worked in

the following sequence: broad variant generation → identifying the 'type', defining it with a verbal description and parametrising it in Grasshopper → feedback from the diffusion model (visualisations + prompts) to iteratively refine the design intention. The results obtained are: mosaics of variants, a parametrisation diagram, a final AI visualisation and a description of the final type definition. The final reflection concerned the role of generative imaging at an early stage, its difficulty and relationship to online sources of inspiration and the place of AI in the designer's tool kit.

Block 02 (generation of a functional layout), conducted by Jakub Oszczyk MSc Arch., is a comparison of two strategies for creating functional floor plans for single-family houses: manual and automated (Rhinoceros+Grasshopper). In the manual part, the students documented their own workflow, identifying advantages, disadvantages and possible improvements; in the automated part, they designed using a generative system prepared by the instructor, documented iterations and compared them with the manual results.

Block 03 (solar analysis), conducted by Krystian Kwieciński, PhD Arch., analysed the insulation of single-family houses: simulations of plot shading for the equinoxes and the summer and winter solstices, and an assessment of illumination using the *daylight factor*, *daylight autonomy* and *useful daylight illuminance* metrics. The analyses were carried out in Rhinoceros+Grasshopper using the Ladybug and Honeybee extensions. On the basis of these, Variant 1 and a modified Variant 2 (adjustment of the location and size of glazing, addition of shading elements) were developed and compared in terms of improving the insulation of the rooms.

Block 04 (LCA and carbon footprint) was led by Mateusz Płoszaj-Mazurek, PhD Arch. It involved the environmental life cycle assessment (LCA) of single-family houses and the demonstration of how environmental analyses shape design decisions. The students performed a sample manual calculation for a selected partition, prepared

a bill of quantities for the main partitions and calculated the embodied carbon footprint of the base concept. They then proposed material and structural options (partition layers, technology, solid), comparing their impact on the outcome and presenting the contribution of the components to the total footprint.

The final projects were evaluated in terms of the quality of documentation of the experiments carried out. We paid attention primarily to the informed use of the tools as evidenced by the descriptions, and less so to the results obtained. A compilation of the results from all four workshop blocks was ultimately presented on one design board. Figures 1a to 1d show an example of a final board made according to a scheme we required, clearly showing the sequence of work (Fig. 1a–1d). Originally, the boards were folded vertically with the layout of the blocks in one column starting with the first at the top and the fourth at the bottom of the board.

4.2. Assumptions and configuration for process replication

Prior to the class, the author prepared all the workstations in the computer lab, uploading the necessary software and standardising the settings to increase the comparability of the results. A description of the configuration of the computers can be found in Appendix 1 of the article.

Given the limited time available for the workshop (5 hours), the author used a standardised baseline *prompt* and a negative *prompt* to reduce the number of trials and errors and increase comparability. A prompt is a textual hint for a diffusion model that specifies what is (or is not) to be generated.

Baseline prompt: *large house with slant roof. simple architectural ((physical model)). minimalist, simplistic, conceptual. isometric view from the top, typology.*

Negative prompt: *rendering, photography, visualisation, digital art, grass, trees. photo, sketch-up, sketch, small, no roof.*

At the beginning of the class, the students were given template sheets to fill in with information about the results of their work. They were to consist of mosaics of variants obtained with AI, a definition of the house type, diagrams of its parametrisation, visualisations resulting from the combination of the parametric model and the operation of AI, and critical conclusions and reflections. The data for the analysis are the final charts and student reflections on the course, which are summarised in the Conclusions section.

4.3. Detailed description of the workshop on the use of AI

The block focused on linking parametric modelling to text- and image-driven generative imaging. The author's aim was to test whether tools of a new type – diffusion models (specifically Stable Diffusion) – are useful at the early stages of the creative process, i.e. whether they accelerate the broad search for solutions and the iterative refinement of design intent. During the five-hour class, the author conducted three exercises preceded by a brief description of how to use Stable Diffusion and, more specifically, the locally run WebUI.

4.3.1. Exercise 1: Type exploration and 'type' selection

The students gathered images using search engines (e.g. Google) and aggregators (e.g. Pinterest) and generated them in parallel in Stable Diffusion using a generic prompt prepared by the instructor. The collected variants were arranged in mosaics (Fig. 2). The collections were organised into typological categories, after which one was selected and a 'type' was defined verbally: a set of necessary characteristics and exclusionary characteristics determining the classification of a house to a given category. The textual type definition was entered as a prompt into Stable Diffusion and refined until the visual results matched the students' intentions. In this exercise, AI control was limited to the *text-to-image* (T2I) method of generating images from text.

4.3.2. Exercise 2: Minimum parametric model (Grasshopper)

When the possibilities of influencing the results through text had been exhausted, the author presented the students with an image-to-image (I2I) control method. This method also allows adding a base image to the prompt and negative prompt, which influences the result through colours and composition. It is possible to control how much influence the image has compared to the text. The author also showed the more selective image control methods possible in the ControlNet module. The control signal (*guidance*) can be limited to an edge (Canny) or depth map (Depth) (Fig. 3). In these scenarios, the input image is pre-processed (into a linear form or a depth map) and the resulting representations condition the de-noising process (image generation) in the diffusion model so that the model 'tries' to preserve the linear drawing or three-dimensional form of the baseline image as a result. This form of control allows the user to focus on form and articulation, leaving the choice of detail and materials to the diffusion model. See Figure 4 for a summary of the control methods. It shows the results of generating images based on the same prompt, but with different control layers added (images from Fig. 3).

After a presentation of the I2I and ControlNet methods, the author gave the students the task of developing a simple volumetric representation of a house type with key parameters (proportions, roof pitch, opening relationships) in the VPL (Grasshopper) environment. The author then presented an extension he had developed for Grasshopper, which linked this software to Stable Diffusion and allowed the visual representation of the model to be used in the previously mentioned I2I and ControlNet strategies.

4.3.3. Exercise 3: Decision loop and model refinement

Finally, the parametric model was enriched with details 'suggested' by the diffusion model (e.g. arcades, atrium form, roof articulation) or, on the

contrary: it was detailed in such a way as to exclude unwanted variants. This process continued iteratively until a satisfactory form was achieved, which was a combination of a particular set of parameters, prompts and diffusion model settings.

At the end of the block, each student team had a simple 3D model (volume representing the type) and one leading visualisation. These formed the starting point for the subsequent tasks: functional layout automation (Block 02), insolation analyses (Block 03) and LCA (Block 04), where the conceptual vision was successively refined, verified and environmentally balanced. After each subsequent block, the students were encouraged to revisit the assumptions from block one. An example would be discovering that it is not possible to design a sensible functional layout on a given plan and that the basic parameters need to be changed. It was assumed that such a change would be as simple as possible thanks to the method developed: the parametric model after editing can be transferred with the same settings to Stable Diffusion, so that the 'visualisation' after the changes is produced very quickly.

Figures 5, 6 and 7 show examples of the results obtained by the students. In the margins of the boards, on the left-hand side, space was provided for a description of the process and a reflection on the use of AI in design. The remainder of the board was dedicated to (from the top) providing an overview of the solutions with labelled images meeting the definition of the selected type, an illustration of the parametric model with variants, a selection of visualisation samples from subsequent iterations and the final result.

5. Results – analysis of students' reflections

The author collected and analysed descriptions of the process and the 'reflections' on the use of AI in design that were placed on the boards by each of the student teams. Below is a summary of the answers. If the number of answers in a category does not add up to 100%, it means that not

every group gave an answer for this category.

The utility of AI in ideation. 22 out of 25 teams (88%) found generative AI to be a real support in the concept phase: it speeds up the generation of multiple variants and 'expands the field of view' of the designer. The statements highlighted the rapid testing of disparate leads and the ability to 'jump' between directions without costly modelling of each of them.

State of design competences. 21 out of 25 teams (84%) indicated that the tool is no substitute for knowledge and experience: without design preparation, it is difficult to select meaningful outcomes and assess their feasibility. An oft-repeated opinion is that artificial intelligence can act as an 'accelerator', but not a 'design machine'.

The role of an untrained. 19 out of 25 (76%) believe that while a layperson can 'get renderings', this is not equivalent to doing valuable conceptual work. The need for creative awareness that allows distinguishing good proposals from poor ones was emphasised.

The most common difficulties associated with the use of generative AI:

- *Language and precision of prompts* – 13 out of 25 teams (52%): difficulty in formulating prompts so that several requirements (for example, a specific number of windows, a specific shape) are met at the same time; extensive negative prompts and many iterations are required to achieve the intended form of the building.
- *Control and repeatability* – 13 out of 25 teams (52%): 'randomness' of the effects, difficulty in predicting the impact of a single change in the settings and prompts; frequent discrepancy between intention and outcome.
- *Semantic errors/geometry* – 3 out of 25 teams (12%): incorrect roofs, 'levitating' storeys, misreading of the outline from the baseline images; effective in correcting these errors was the expansion of negative prompts and the strengthening of control via geometry with ControlNet.

Comparison with search engines (Pinterest/Google/IG). 11 out of 25 teams (44%) explicitly compared the two ways of working: search engines provide 'someone else's examples', while generative AI allows you to produce and conduct a solution review according to your own vision. At the same time, it was emphasised that search engines are better for verifying real-world references (materials, details, design) – something that is often lacking in the generative process, as AI models can 'make up' unrealistic variants and hide the source of the results.

Introducing AI into one's own design tool kit. The students' declarations regarding their willingness to use AI divide almost equally: 12 out of 25 (48%) answered 'yes / AI should be an integral part of the tool kit'; 11 out of 25 (44%) allowed the use 'conditionally / not universally' (only as an add-on, depending on the context and stage of the work). 8 out of 25 teams (32%) indicated that it was important to have and develop competence in the use of AI in architectural design. Unambiguous opposition to the popularisation of this technology was expressed by 3 out of 25 teams (12%).

The need for visual control elements. 11 out of 25 teams (44%) reported introducing the parametric 3D model as prompts for the generator as an item that is necessary to achieve the intended solid (e.g. a clear terrace plane, atrium contours, precise definition of the roof slope).

A selection of examples of statements by students-participants can be found in Appendix 2 of the article.

6. Discussion

In the exercises conducted by the author, combining a simple parametric model (Grasshopper) with image generation in Stable Diffusion controlled by ControlNet and working in a human-in-the-loop arrangement helped the students to test the building 'types' more quickly and clearly and then bring one of them to that status of a coherent concept. The key conclusion is

that the addition of geometric conditions (simple visualisation of solids) to textual prompts greatly increases control over diffusion models – to a level that is useful in design. This means that AI only shows potential when its user has specific intentions and at least the basic ability to express them visually (e.g. in a sketch or 3D model). Using the Grasshopper software extension, which automatically transfers the view to Stable Diffusion along with parametric modelling capabilities, made the search for solutions intuitive and fast.

The results obtained in the author's exercises are consistent with the conclusions of the literature indicating that AI tools should enhance creativity and problem solving, and should not replace authorship. The inclusion of a simple parametric model (Grasshopper) as a control layer and the work in the human-in-the-loop organised the exploration of 'types' and accelerated the transition from a broad overview of variants to a coherent concept. In this sense, our approach fits in with the recommendation that design studies should teach both concept generation with the help of AI and the competence to manage the whole generative process, keeping decision-making on the human side¹⁸ The ability to name design intentions – purpose, constraints and features of the desired solution – is also proving important. Research into the use of text-based image-generating AI shows that 'writing to the tool' can be a competence in itself – the word choice and prompt structure significantly affect the outcome, and longer, structured descriptions are more likely to lead to higher quality results¹⁹. In other words, the quality of the image sometimes depends on the quality of the description. This is in line with the trend of

¹⁸ M. El Moussaoui, K. Krois, *Architectural Pedagogy in the Age of AI: The Transformation of a Domain*, in: *School of Architecture(s) – New Frontiers of Architectural Education. EAAE Annual Conference – Turin 2023*, eds. M. Barosio, E. Vigliocco, S. Gomes, Cham 2025, pp. 87–93.

¹⁹ V. Paananen, J. Oppenlaender, A. Visuri, *Using text-to-image generation for architectural design ideation*, "International Journal of Architectural Computing", vol. 22, 2023, no. 3, pp. 458–474.

developing interfaces that are increasingly based on natural language. This is an argument for deliberately practising ‘talking and writing about architecture’ in education as part of the design process, rather than just the final communication.

What surprised the author was the difference between the high rating of AI’s usefulness for ideation and the moderate rate of declarations of permanently incorporating these tools into one’s own tool kit – some students pointed to ‘randomness’ and the problem of repeatability. A possible explanation is the hardware barrier: working on studio computers with low-performance graphics cards that we had access to significantly increased the time of each iteration and discouraged experimentation and parameter adjustment.

From a pedagogical point of view, it seems valuable to ‘demystify’ an unfamiliar technology that causes growing concern. One of these concerns undoubtedly includes the fear – in this case of architects – of being replaced by artificial intelligence. The reflections we collected clearly indicate that, after learning about the limitations of image-generating AI models, the students became sceptical about this way of working. In future editions of the course, it would be worthwhile to conduct surveys also before the classes and see if students’ attitudes towards AI-based tools have changed after the workshop. It also seems promising to compare the two ways of working on the occasion of the main semester design: giving some students access to tools such as diffusion models at the ideation stage, and comparing them at the end of the semester with a control group that did not have such access. This would provide a basis for assessing whether the benefits of using AI are real.

Finally, it is worth noting that the basic use of generative AI, i.e. only creating images by typing prompts into publicly available tools, does not align with professional practice in large design studios. Companies that are leaders in the implementation of innovative tools are developing their own complete workflows based on proprietary

tools and their own servers. Foster + Partners, for example, has implemented a company plug-in that runs diffusion models directly with Rhinoceros (including generating images on the basis of existing geometry), and for ideation they use a locally run Stable Diffusion to protect data and intellectual property²⁰ (by the way, this is very similar to the methods presented in this article). Heatherwick Studio declares a shift from off-the-shelf solutions to custom models trained on internal data and an image generation tool maintained on a local server²¹. This is due to concerns about intellectual property, but also the quality and originality of the solutions. Zaha Hadid Architects have been developing original AI-based solutions since the beginning of their popularisation in 2021. They have tried to train models on their data, using it primarily to speed up iterations of project work, most often through visualisations. Aware of the limitations of general-purpose tools, especially in terms of the ‘understanding’ of tectonics and structures, they are working on a 2D–3D bridge and integrating different modelling software. The aim is to extend the ‘competence’ of AI to creating useful three-dimensional geometry consistent with structural logic²².

7. Conclusions

Generative AI in the exercises conducted by the author clearly widened the search space and accelerated ideation, but did not replace the design competence or judgement of the designer. In

²⁰ Foster + Partners, *Design, Technology, and the Team Between* (+Plus Journal), <https://www.fosterandpartners.com/insights/plus-journal/design-technology-and-the-team-between> (accessed on 31 October 2025).

²¹ D. Chevin, *How Heatherwick humanises buildings... with technology*, “Construction Management”, 6 December 2024, <https://constructionmanagement.co.uk/how-heatherwick-humanises-buildings-with-technology/> (accessed on 31 October 2025).

²² J. Bell, *AI in architecture: Zaha Hadid Architects on its pioneering use and collaborating with NVIDIA*, “Wallpaper”, <https://www.wallpaper.com/architecture/zaha-hadid-architects-nvidia-ai-in-architecture> (accessed on 31 October 2025).

some cases, it even gave the impression of hindering obtaining the outcome that the student group in question was able to imagine and even model on its own. The coupling of parametric modelling (Grasshopper) with generative imaging via image-to-image/ControlNet (especially Canny and Depth) yielded the best results: the students maintained control over the geometry and were more likely to get the result to match the intention, discovering simple mapping rules (e.g. colour-beige → material-wood). The main barrier was controllability and repeatability – there was stylistic ‘drift’ and inconsistent or incorrect geometry. We were significantly limited by the available computer hardware (graphics cards with the minimum required specifications), which lengthened the iterations. Access to better performing resources would significantly increase the educational value and remove the possible negative impact on students’ evaluation of the tool. The standardisation of the process (common prompts, a limited set of ControlNet models and channels) allowed the results to be comparable and the workshops to be conducted in a short time, which is particularly important in view of the overloaded curricula. The conclusions we have drawn relate to a single university year and a strictly defined environment, so they should be generalised with caution. In summary: the greatest value comes from assisted design – human + AI – introduced in the curriculum when students are already able to critically evaluate results and add their own controls, and the gradual discussion of techniques (T2I → I2I → parametric model → ControlNet) allows a good understanding of the capabilities and limitations of artificial intelligence.

Appendix 1. Software configuration

Below is a description of the configuration the author chose for the classes:

- Stable Diffusion WebUI 1.6.0 (AUTOMATIC1111) run with API (--api) enabled and memory optimisations --xformers and --medvram (resulting from the necessary performance trade-offs on lower-performance graphics cards

installed in the classroom). These parameters are officially documented in the WebUI project.

- *ControlNet for Stable Diffusion WebUI* extension. Of the ControlNet models, the author used Canny (edge detection) and Depth-Midas (depth-map), which, in his own testing prior to the start of the course, proved most useful in controlling the diffusion model through renderings of a simple parametric solid.
- Rhinoceros 7 + Grasshopper together with a proprietary extension to communicate with the WebUI API. The extension prepared by the author allowed the full prompt to be configured for Stable Diffusion and automated the transfer of the current view from Rhinoceros to the ControlNet module. This greatly facilitated the generation of subsequent iterations and their documentation.
- Base models (checkpoints) for Stable Diffusion: realisticVisionV60B1_v51VAE, deliberate_v6, reliberate_v3 (distributed by hugging-face; selected after quality testing).
- LoRA (Low-Rank Adaptation) – lightweight styling modules that impose the aesthetics of architectural models. The author deliberately limited the photorealism to focus the students’ attention on solids and type. The LoRAs we used are no longer available at the time of writing of this article.

Appendix 2. Examples of students-participants’ statements (selection)

Usability in design:

‘Generative artificial intelligence is very useful during concept development. It allows up to several dozen different solutions or variations of the same idea to be tested quickly.’

‘Generative AI helps with conceptual work, giving the opportunity to create multiple versions with different settings, showing examples we wouldn’t have come across on our own.’

‘Generative artificial intelligence, especially in Grasshopper and Stable Diffusion, is revolutionising my conceptual architectural work.’

‘Artificial intelligence allows the rapid generation of visual solutions that can propose solutions (e.g. material, solid) that the author would not have come up with on his or her own.’

Condition of experience and skills:

‘While the tool can be inspiring, the design experience still plays a key role in the successful use of generative artificial intelligence.’

‘It is up to the architect to filter out which options are feasible and which are just a pretty picture with no real chance of being built.’

‘For designing solutions that are not only aesthetically pleasing but also functional, a foundation of design teaching is essential.’

‘Without knowledge of design, it would be impossible to distinguish between good AI prompts and bad ones, and the process itself without your own thoughts could prove shallow.’

Difficulties with control:

‘The prompt has to be very precise, and sometimes we do not get satisfactory results even despite many attempts.’

‘A barrier to working with AI seems to us to be the limitation of control over the variants produced – when generating successive iterations, it is difficult to precisely change specific features without affecting the others.’

‘Unfortunately, it is often difficult to communicate to the AI what exactly we want to get in the picture, which is the biggest difficulty in using it.’

‘A possible big difficulty is choosing the right prompts. Without a suggestion in the form of a graphic, for example, it can be difficult to achieve the desired effect.’

Bibliography

Alymani A.A.A., *Integrating Artificial Intelligence Rendering Tools in Design: Integrating AI as teaching methods in architectural education*, in: *Data-Driven Intelligence. Proceedings of the 42nd Conference on Education and Research in Computer Aided Architectural Design in Europe (eCAADe 2024)*, vol. 2, eds. O. Kontovourkis, M. C. Phocas, G. Wurzer, Nicosia 2024, DOI: 10.52842/conf.ecaade.2024.2.629

Bell J., *AI in architecture: Zaha Hadid Architects on its pioneering use and collaborating with NVIDIA*, “Wallpaper*”, 13 December 2024, <https://www.wallpaper.com/architecture/zaha-hadid-architects-nvidia-ai-in-architecture>

Bernstein P., *Machine Learning: Architecture in the Age of Artificial Intelligence*, London 2022, DOI: 10.4324/9781003297192

Bolojan D., *Creative AI: Augmenting Design Potency*, “Architectural Design”, 2022, no. 92(3), DOI: 10.1002/ad.2809

Campo M., *The Digital Turn in Architecture 1992–2012*, Chichester 2012

Campo M., *The Second Digital Turn: Design Beyond Intelligence*, Cambridge MA 2017

Chevin D., *How Heatherwick humanises buildings... with technology*, “Construction Management”, 6 December 2024, <https://constructionmanagement.co.uk/how-heatherwick-humanises-buildings-with-technology/>

Cudzik J., Nyka L., Szczepański J., *Artificial intelligence in architectural education – green campus development research*, “Global Journal of Engineering Education”, 2024, no. 26(1), DOI: 10.1011/gleej1050

El Moussaoui M., Krois K., *Architectural Pedagogy in the Age of AI: The Transformation of a Domain*, in: *School of Architecture(s) – New Frontiers of Architectural Education. EAAE AC 2023*, eds. M. Barosio, E. Vigliocco, S. Gomes, Cham 2025, DOI: 10.1007/978 3 031 71959 2_11

Foster + Partners, *Design, Technology, and the Team Between*, “+Plus Journal”, <https://www.fosterandpartners.com/insights/plus-journal/design-technology-and-the-team-between>

Horvath A.-S., Pouliou P., *AI for conceptual architecture: Reflections on designing with text-to-text, text-to-image, and image-to-image generators*, “Frontiers of Architectural Research”, vol. 13, 2024, no. 3, DOI: 10.1016/j.foar.2024.02.006

- Jin S., Tu H., Li J., Fang Y., Qu Z., Xu F., Liu K., Lin Y., *Enhancing Architectural Education through Artificial Intelligence: A Case Study of an AI-Assisted Architectural Programming and Design Course*, "Buildings", vol. 14, 2024, no. 6, DOI: 10.3390/buildings14061613
- Leach N., *Architecture in the Age of Artificial Intelligence: An Introduction to AI for Architects*, London–New York 2022, DOI: 10.36253/techne-14769
- Oxman R., *Thinking difference: Theories and models of parametric design thinking*, "Design Studies", 2017, vol. 52, DOI:10.1016/j.destud.2017.06.001
- Özorhon G., Nitelik Gelirli D., Lekesiz G., Müezzinoğlu C., *AI-assisted architectural design studio (AI-a-ADS): How artificial intelligence join the architectural design studio?*, "International Journal of Technology and Design Education", vol. 35, 2025, no. 5, DOI: 10.1007/s10798-025-09975-0
- Paananen V., Oppenlaender J., Visuri A., *Using text-to-image generation for architectural design ideation*, "International Journal of Architectural Computing", vol. 22, 2023, no. 3, DOI: 10.1177/14780771231222783
- Ploennigs J., Berger M., *AI art in architecture*, "AI in Civil Engineering", vol. 2, 2023, no. 1, art. 8, DOI: 10.1007/s43503-023-00018-y
- Royal Institute of British Architects, *RIBA AI Report 2024*, <https://www.architecture.com/knowledge-and-resources/resources-landing-page/riba-ai-report-2024>
- Słyk J., Ostrowska-Wawryniuk K., Strzała M., *Form Follows Parameter: Algorithmic Thinking Oriented Course for Early Stage Architectural Education*, "Nexus Network Journal", vol. 24, 2022, no. 2, DOI: 10.1007/s00004-022-00603-1
- Yiannoudes S., *Shaping Architecture with Generative Artificial Intelligence: Deep Learning Models in Architectural Design Workflow*, "Architecture", vol. 5, 2025, no. 4, DOI: 10.3390/architecture5040094
- Yuan P. F., *Toward a generative AI-augmented design era*, "Architectural Intelligence" 2023, vol. 2, 2023, no. 1, art. 16, DOI: 10.1007/s44223-023-00038-9
- Zhang H., Zhang R., *Generative artificial intelligence (AI) in built environment design and planning – A state-of-the-art review*, "Progress in Engineering Science", vol. 2, 2025, no. 1