

*Informatyka w Edukacji, XXI
UMK Toruń, 2025*

DOBRE PRAKTYKI W NAUCZANIU SZTUCZNEJ INTELIGENCJI: WYZWANIA I ROZWIĄZANIA DLA SZKOLNICTWA WYŻSZEGO W 2025 ROKU

Tadeusz Kifner

*Polskie Towarzystwo Informatyczne,
Uniwersytet MERITO Gdańsk*

tadeusz.kifner@pti.org.pl; <https://www.linkedin.com/in/tadeuszkifner/>

Abstract. *The rapid proliferation of AI-powered solutions, especially easy accessed Software-as-a-Service (SaaS) is fundamentally transforming the landscape of education. This article presents a comprehensive methodology for teaching artificial intelligence (AI) that balances the use of modern tools for understanding of underlying mechanisms of AI. It addresses the challenge of preventing students from becoming mere consumers of AI platforms by emphasizing hands-on experience, theoretical foundations, and critical thinking. The evolution from traditional neural networks to transformer-based architecture is discussed in relation to visualizing AI concepts and building appropriate laboratory environments for student's tasks, allowing experimentation with AI models. The article also explores the risks associated with integrating AI into higher education, including academic integrity and ethical concerns. The proposed approach aims to equip lecturers with methods and students with both practical skills and a critical understanding of AI, ensuring all are prepared for the challenges in rapid evolving landscape.*

1. Wstęp

Współczesna edukacja z zakresu sztucznej inteligencji (SI), w szczególności na poziomie akademickim, stoi przed bezprecedensowymi wyzwaniami związanymi z dużą dostępnością tanich usług SaaS opartych o narzędzia SI. Powoduje to wśród studentów odejście w procesie uczenia od zgłębiania fundamentalnych mechanizmów SI na rzecz


używania jedynie gotowych narzędzi do rozwiązywania generalnych lub specjalizowanych problemów. Następuje coraz większy brak rozumienia zaawansowanych algorytmów SI oraz sposobu działania SI i sposobu pracy SI. Niniejszy referat przedstawia metodykę nauczania o sztucznej inteligencji, która łączy tradycyjne podejścia z nowoczesnymi narzędziami, zapewniając studentom zarówno teoretyczne podstawy, jak i praktyczne umiejętności implementacyjne. W artykule przedstawiono ewolucję od klasycznych sieci neuronowych do architektur transformerowych. Jednocześnie wskazano metody wizualizacji złożonych konceptów SI oraz wymagania infrastrukturalne dla laboratoriów uniwersyteckich. Zidentyfikowano także kluczowe ryzyka związane z nauką o SI w szkolnictwie wyższym.

2. Współczesne wyzwania w edukacji o sztucznej inteligencji

Rok 2025 charakteryzuje się masową dostępnością zaawansowanych narzędzi SI w modelu Software-as-a-Service. Fundamentalnie zmienia to krajobraz edukacyjny z uwagi na możliwy szybki dostęp do uporządkowanej i logicznie poukładanej informacji [4]. Studenci mają dziś natychmiastowy dostęp do narzędzi takich jak ChatGPT, Perplexity, Claude czy Gemini, jednak ta dostępność paradoksalnie może prowadzić do powierzchownego zrozumienia mechanizmów działania SI [15]. Badania pokazują, że studenci stają się jedynie konsumentami technologii SI. Nie rozumieją fundamentalnych procesów obliczeniowych, które umożliwiają funkcjonowanie tych systemów oraz nie pamiętają o ograniczeniach tej technologii [6].

SI w połączeniu z dużymi możliwościami obliczeniowymi obecnych centrów danych współczesne systemy SI, oparte na architekturach transformerowych, znacząco odbiegają od tradycyjnych rozwiązań SI, tj. sieci neuronowych, i wymagają też innego sposobu zarządzania [16]. Sytuacja ta zmienia też rolę wykładowców którzy muszą opracować nowe strategie dydaktyczne [8], ale także wcielić się w rolę architekta i administratora środowisk laboratoryjnych. Konieczne jest więc znalezienie równowagi między wykorzystaniem nowoczesnych narzędzi SaaS (ang. *Software as a Service*) dostępnych online z środowiskiem laboratorium służącym do głębokiego zrozumienia podstawowych mechanizmów działania sztucznej inteligencji [10].

Na rysunku 1 przedstawiono metodykę pracy wykładowcy.



Rysunek 1. Metodyka pracy z SI zawierająca podział na tradycyjną i nowoczesną SI


Przejsie od tradycyjnych sieci neuronowych do nowoczesnych architektur transformerowych reprezentuje fundamentalną zmianę paradygmatu w dziedzinie SI. Klasyczne podejścia oparte na konwolucyjnych sieciach neuronowych (CNN) i rekurencyjnych sieciach neuronowych (RNN) wymagały od studentów zrozumienia lokalnych wzorców przetwarzania informacji oraz sekwencyjnej natury obliczeń [18]. Współczesne architektury transformerowe wprowadzają mechanizm uwagi (ang. attention), który umożliwia równoległe przetwarzanie całych sekwencji, oraz mechanizm taktowania przetwarzania w sposób iteracyjny i postępujący. SI generuje tekst token po tokenie, wykorzystując mechanizm autoregresyjny oparty na samouwadze (self-attention).

Każdy krok generacji polega na przewidywaniu następnego tokenu na podstawie dotychczasowej sekwencji, co można interpretować jako iteracyjne budowanie struktury odpowiedzi. Fundamentalnie to zmienia sposób, w jaki modele "rozumieją" kontekst świat i jak można je wykorzystać [19]. Badania porównawcze wskazują, że transformery często przewyższają tradycyjne architektury w zadaniach wymagających zrozumienia długoterminowych i złożonych zależności i konceptów, jednak w niektórych zastosowaniach sieci neuronowe dalej są efektywne i mogą być jednocześnie mniej kosztowne [1]. Sytuacja wymaga więc od edukatorów opracowania strategii, które pozwolą studentom zrozumieć: historyczny kontekst rozwoju SI, nowoczesne podejścia oraz gdzie i w jakim zakresie stosować optymalnie SI.

3. Metodyka nauczania SI

4.1. Zasady przewodnie edukacji SI

Skuteczna metodyka nauczania sztucznej inteligencji w erze SaaS musi opierać się na kilku fundamentalnych zasadach [9]. **Zasada progresji** zakłada stopniowe wprowadzanie studentów w coraz bardziej złożone koncepty, rozpoczynając od podstawowych perceptronów, przechodząc przez uproszczone sieci neuronowe, głębokie sieci neuronowe, koncepcję LSTM do nowoczesnych architektur transformerowych. **Zasada kontrastu** wymaga ciągłego porównywania tradycyjnych i nowoczesnych podejść, np. sieci RNN z LSTM, albo LSTM z Bert, umożliwiając studentom zrozumienie ewolucji algorytmów i ograniczeń każdego podejścia dając jednocześnie studentom możliwość samodzielnej eksploracji i uczenia się w trybie indywidualnym [12]. **Zasada praktyczności** oznacza, że model czy koncept pokazany teoretycznie musi być wspierany przez jego implementację praktyczną. Student powinien kodować algorytmy czy to samodzielnie, czy z pomocą przygotowanych wcześniej ćwiczeń w laboratoriach. Pozwala to studentom na eksperymentalne zweryfikowanie teoretycznej wiedzy i osiągnięcie określonego celu (działającego programu). **Zasada krytycznego myślenia** zakłada rozwój umiejętności analizy realnego środowiska używania SI, w tym ograniczeń, ryzyk i etycznych implikacji dotyczącej sztucznej inteligencji. Te zasady razem tworzą ramy dla zrównoważonej edukacji, która przygotowuje studentów zarówno do wykorzystywania dostępnych narzędzi, jak i do krytycznej oceny ich możliwości i ograniczeń.



Rysunek 2. Cztery zasady przewodnie edukacji SI

4.2. Struktura modułowa kursu

Proponowana struktura kursu – będąca konsekwencją wymaganej zmiany sposobu uczenia – obejmuje pięć głównych modułów, z których każdy adresuje specyficzne aspekty współczesnej edukacji SI.

Moduł I: Fundamenty i historia SI koncentruje się na zbudowaniu solidnych podstaw teoretycznych, wprowadzając studentów w historię rozwoju dziedziny od perceptronów, poprzez LSTM, do współczesnych LLM. Ten moduł jest kluczowy dla zrozumienia ewolucji myślenia o sztucznej inteligencji i umożliwia studentom docenianie ostatnich zmian i rozwoju tej dziedziny.

Moduł II: Głębokie uczenie się zagłębia się w tradycyjne architektury głębokiego uczenia, w tym CNN i RNN. Tym samym studenci pozyskują solidne podstawy w klasycznych podejściach SI.

Moduł III: Uczenie iteracyjne gdzie studenci zapoznają się z iteracyjnością działania modeli SI opartych o LSTM (Long Short Term Memory), gdzie podstawą jest taktowanie w cyklach działania SI i dostarczanie wyników w sposób zależny od postępów i czasu.

Moduł IV: Era transformerów wprowadza nowoczesne architektury oparte na mechanizmie uwagi i budowie kontekstu, wyjaśniając fundamentalne różnice w stosunku do tradycyjnych podejść.

Moduł IV: Nowoczesne podejścia i SaaS łączy teoretyczne zrozumienie z praktycznym wykorzystaniem dostępnych narzędzi, ucząc studentów jak skutecznie korzystać z API, które dostarczają usługi SI w modelu chmurowym. Jednocześnie wskazywany jest w module etyczny aspekt stosowania SI w życiu codziennym, np. w motoryzacji, logistyce czy handlu.

Moduł V: Praktyczne zastosowania koncentruje się na i rozwijaniu umiejętności stworzenia działających komponentów informatycznych w środowisku laboratorium lub na maszynach studentów w celu wykonania konkretnych działań. Bazą może być rozpoznawanie obrazów z użyciem grafiki z biblioteki MNIST, analiza dzieł literackich albo wpisów w social media, szukanie granic decyzyjnych na podstawie zbiorów statystycznych.

4.3. Wizualizacja i metody graficzne w edukacji SI


Ważną kwestią jest odpowiedni dobór środków wizualizacyjnych pokazujących działanie SI. W tym celu należy przygotować środowisko laboratorium w sposób umożliwiający zapisywanie bieżącego stanu modelu SI wraz z narzędziami do raportowania postępów. Dobrą praktyką jest przygotowanie:

- dashboardów z działania SI zawierających podstawowe wskaźniki i pokazujących wyjścia z modelu, np. z każdej warstwy RNN,
- nagrywanie postępów SI w postaci filmów wskazujących kolorem lub nasyceniem poziom sygnału wyjścia sztucznego neuronu i propagację tych sygnałów w sieci.

Istnieje grupa problemów dla SI, w szczególności tych związanych z decyzjami w czasie, np. podejmowanie decyzji na podstawie prognoz pogody czy ruchu pojazdów, które świetnie nadają się do wizualizacji dla studentów. W ten sposób buduje się świadomość konkretnej przydatności stosowanych algorytmów SI.


4.4. Interaktywne narzędzia wizualizacji

Jak wskazano powyżej skuteczne nauczanie złożonych konceptów sztucznej inteligencji wymaga wykorzystania zaawansowanych metod wizualizacji. Zrozumienie abstrakcyjnych procesów obliczeniowych SI jest bardziej możliwe w trakcie samodzielnych eksperymentów. CNN Explainer stanowi przykład interaktywnego narzędzia, które pozwala studentom na eksplorację mechanizmów konwolucji w czasie rzeczywistym, wizualizując przepływ danych przez kolejne warstwy sieci [21]. Transformer Explainer umożliwia zrozumienie mechanizmu uwagi (ang. attention) przez interaktywną manipulację parametrów i obserwację wpływu na wyniki modelu SI.



Rysunek 3. CNN Explainer

Innym przydatnym narzędziem jest Neural Network Playground oferuje intuicyjny interfejs do eksperymentowania z podstawowymi architekturami sieci neuronowych, pozwalając studentom na obserwację wpływu różnych parametrów na proces uczenia. Koncepcja Neural Network Playground powstała w odpowiedzi na wyzwania związane z barierami kodowania skomplikowanych równań matematycznych i abstrakcyjnych konceptów przez studentów. TensorFlow Playground jest narzędziem edukacyjnym, które przekształca złożone idee w interaktywne, wizualne reprezentacje. TensorBoard zapewnia profesjonalne narzędzia do wizualizacji procesu treningu, umożliwiając studentom monitorowanie zbieżności, analizę gradientów oraz wizualizację reprezentacji wewnętrznych. Możliwa jest też wizualizacja skomplikowanych architektur modeli, pomagając studentom w zrozumieniu przepływu danych przez złożone sieci neuronowe.



Rysunek 6. Prezentacje danych 3D

Klasa narzędzi do wizualizacji uwagi (ang. attention visualizers) są wartościowe przy nauczaniu studentów architektur transformerowych, pozwalając im na obserwację jak wygląda propagacja sygnałów wejścia wewnątrz modelu SI, czyli na co model "zwraca uwagę" podczas generowania odpowiedzi [3].

Metodyka wizualizacji musi być dostosowana do poziomu zaawansowania studentów, rozpoczynając od prostych diagramów blokowych i stopniowo wprowadzając bardziej zaawansowane reprezentacje. Dla studentów początkujących, wizualizacje powinny koncentrować się na wysokopoziomowych conceptach, takich jak wejścia/wyjścia z sztucznego neuronu, przepływach danych przez prostą sieć czy ogólnych wizualizacjach warstw i działania neuronów. Studenci zaawansowani mogą korzystać z bardziej szczegółowych wizualizacji, obejmujących przygotowane odpowiednio dashboards, w tym analizę gradientów, wykresy z wizualizacją działania filtrów czy pokazanie map aktywacji.

W nauczaniu kluczowe jest wykorzystanie interaktywnych demonstracji prac studentów oraz wyników działania przygotowanych wcześniej środowisk przez prowadzącego zajęcia. Takie podejście pozwala studentom na eksperymentowanie z parametrami w czasie rzeczywistym [20]. Takie podejście umożliwia ogólne zrozumienie zależności i wpływu różnych parametrów na zachowanie modelu SI [7].

4. Implementacja programu zajęć

4.1. Różnicowanie Poziomów Zaawansowania

Skuteczna implementacja programu zajęć wymaga uwzględnienia zróżnicowanego poziomu przygotowania studentów. **Studenci początkujący** powinni koncentrować się na zrozumieniu fundamentalnych conceptów SI i umieć wykorzystać wysokopoziomowe biblioteki takie jak Keras czy scikit-learn. Dla tej grupy kluczowe jest stopniowanie wiedzy, aby nie spowodować blokady absorpcji nowych informacji. W tym celu można

stosować wizualizacje i interaktywne eksperymenty. Ta grupa jest użytkownikiem narzędzi SI, w tym aktywnie korzysta z usług SI w modelu SaaS.

Studenci zaawansowani mogą podejmować się implementacji algorytmów w dowolnych językach programowania, najczęściej w Python oraz uczestniczenia w projektach typu open-source. Ta grupa może opierać swoją pracę na samodzielnej eksploracji baz wiedzy, w tym publikacji naukowych. Jednocześnie jest w stanie tworzyć samodzielnie osobne architektury świadczące usługi SI w modelu SaaS.

4.2. Integracja z Przemysłem i Praktyką

Współpraca z przemysłem jest kluczowa dla zapewnienia praktycznej relewalności programu nauczania. Zajęcia powinny być prowadzone - przynajmniej częściowo - przez praktyków z firm wykorzystujących SI. Takie podejście daje szansę studentom na wgląd w rzeczywiste zastosowania technologii SI. Omawiane na zajęciach case studies z obszaru przemysłu - czy szerokiego biznesu - oparte powinny być na realnych problemach możliwych do rozwiązania przez studentów. Nie należy wskazywać problemów abstrakcyjnych lub bardzo złożonych.

Projekty w partnerstwie z firmami oferują studentom możliwość pracy nad rzeczywistymi wyzwaniami, np. w ramach praktyk, jednocześnie zapewniając firmom dostęp do świeżych pomysłów i talentów. Staże i praktyki w firmach stanowią naturalną kontynuację procesu edukacyjnego. Nauczyciel akademicki staje się więc mentorem studentów wchodzących na rynek pracy co znacząco zwiększa skuteczność procesu uczenia.

4.3. Ocena i ewaluacja postępów

System oceny musi być dostosowany do specyfiki edukacji SI. Z tego względu powinien zawierać walidację teoretycznego zrozumienia, jak i praktycznej umiejętności implementacji SI. Proponuje się, żeby ocena zawierała następujące części:

- 40% końcowej oceny – obecność na zajęciach i aktywność w dyskusji,
- 40% końcowej oceny – ocena implementacji i wyników eksperymentów,
- 20% końcowej oceny – weryfikacja rozumienia konceptów teoretycznych.

Projekty implementacyjne powinny być dwóch typów: projekt średniookresowy skupiający się na prostych wdrożeniach tradycyjnej i nowoczesnej SI oraz projekt finalny wymagający kompleksowego rozwiązania problemu wraz z analizą wyników. Ważnym elementem jest praktyczne demonstrowanie działających systemów SI lub kawałków algorytmów na zajęciach i wspólne omawianie plusów i minusów danej implementacji.

5. Ryzyka i wyzwania SI w szkolnictwie wyższym

5.1. Zagrożenia dla integralności akademickiej

Masowe wprowadzenie narzędzi generatywnej SI jest wyzwaniem dla integralności akademickiej w szkolnictwie wyższym. Badania wskazują, że wyniki SI są porównywalne lub lepsze od prac studentów, co fundamentalnie podważa tradycyjne metody oceny [17, 5]. Problem ten jest szczególnie istotny w kontekście wzrostu możliwości systemów takich jak Perplexity, Claude czy GPT-4, które mogą generować spójne i merytoryczne odpowiedzi na złożone problemy na poziomie akademickim. Z tego względu stosowanie w uczeniu o SI narzędzi do detekcji plagiatyzmu nie wnosi wartości. Narzędzia te nie są w stanie skutecznie identyfikować kodu programu generowanego przez AI, zwłaszcza, że coraz częściej narzędzia programistyczne korzystają z funkcji SI natywnie, np. copilot. Należy zaakceptować fakt, że przy złożonych koncepcjach studenci będą wspierać się zapytaniami do SI, w szczególności w celu wygenerowania fragmentów kodu źródłowego programów. Z tego względu najważniejszym jest wpływanie na sposób myślenia i działania studentów, a nie walidowanie pochodzenia kodu i tekstów.

5.2. Wpływ na rozwój umiejętności krytycznego myślenia

Nadmiernie opieranie się o narzędzia SI może prowadzić do ograniczenia umiejętności krytycznego myślenia u studentów. Łatwość dostępu do wyników z systemów SI poprzez SaaS może ograniczać rozwój autonomicznych umiejętności problemowych, ponieważ studenci mogą stać się nadmiernie zależni od zewnętrznych narzędzi. W tym może też następować spadek chęci drażenia informacji i szukania relacji w bazie wiedzy skoro w modelu SaaS student otrzymuje tanie i szybkie odpowiedzi. Stąd istnieje pokusa nie rozwijania własnych procesów myślowych [14].

Taka sytuacja może prowadzić do powierzchownego zrozumienia konceptów SI, ponieważ narzędzia AI mogą dostarczać gotowych rozwiązań bez wymagania od studentów przejścia przez złożony proces myślowy [11]. Myślenie kreatywne może ucierpieć, jeśli studenci będą preferować generowane treści, zamiast rozwijać je samodzielnie.

Z tego względu kluczowe jest w procesie edukacyjnym zachowanie zaufania do sposobu oceny gdzie fundamentem jest umiejętność stosowania wiedzy i eksperymentowanie z SI.

6. Wnioski i Rekomendacje

Skuteczna edukacja SI wymaga fundamentalnej zmiany podejścia pedagogicznego, które łączy wykorzystanie nowoczesnych narzędzi prowadzenia laboratoriów z

wizualizacją dla zrozumienia podstawowych mechanizmów SI. Wymagane jest też połączenie teorii z praktyką - studenci muszą zarówno rozumieć matematyczne podstawy algorytmów, jak i umieć wykorzystywać dostępne narzędzia w praktycznych aplikacjach.

Priorytetem jest stopniowe budowanie zrozumienia od prostych konceptów do złożonych systemów wraz z jasnym wyjaśnieniem ograniczeń i ryzyk implementacji. Algorytmy studenci powinni pisać samodzielnie jednak z przyzwoleniem na wspomaganie się narzędziami SI typu copilot. Ważne jest też zapewnienie praktycznej relewantności programu studenta i umożliwienia mu zrozumienia rzeczywistych wyzwań w implementacji systemów SI w biznesie.

Literatura

1. Bai Y, Mei J, Yuille A, Xie C. Are Transformers More Robust Than CNNs? arXiv.org. November 10, 2021. Accessed June 9, 2025. <https://arxiv.org/abs/2111.05464v1>.
2. Bäuerle A, Albus P, Störk R, Seufert T, Ropinski T. exploRNN: teaching recurrent neural networks through visual exploration. *Vis Comput.* 2023;39(9):4323-4338. doi:10.1007/s00371-022-02593-0.
3. Brasoveanu A, Andonie R. Vizualizing Transformers for NLP: A Brief Survey.; 2020. doi:10.1109/IV51561.2020.00051
4. Chakraborty S. Generative AI in Modern Education Society. Published online December 10, 2024. doi:10.48550/arXiv.2412.08666.
5. Chen Z, Chen C, Yang G, et al. Research integrity in the era of artificial intelligence: Challenges and responses. *Medicine.* 2024;103(27):e38811. doi:10.1097/MD.00000000000038811.
6. Denny P, Khosravi H, Hellas A, Leinonen J, Sarsa S. Can We Trust AI-Generated Educational Content? Comparative Analysis of Human and AI-Generated Learning Resources. Published online July 3, 2023. doi:10.48550/arXiv.2306.10509.
7. Dragly SA, Hobbi Mobarhan M, Våvang Solbrå A, et al. Neuronify: An Educational Simulator for Neural Circuits. *eNeuro.* 2017;4(2):ENEURO.0022-17.2017. doi:10.1523/ENEURO.0022-17.2017.
8. Franklin D, Denny P, Gonzalez-Maldonado DA, Tran M. Generative AI in Computer Science Education: Challenges and Opportunities. *Elements in Generative AI in Education.* Published online April 2025. doi:10.1017/9781009581738.
9. Kamalov F, Calong DS, Gurrib I. New Era of Artificial Intelligence in Education: Towards a Sustainable Multifaceted Revolution. Published online October 25, 2023. doi:10.48550/arXiv.2305.18303.
10. Khan F, Bose D. Artificial Intelligence enabled Smart Learning. arXiv.org. January 8, 2021. Accessed June 9, 2025. <https://arxiv.org/abs/2101.02991v1>.

11. Klimova B, Pikhart M. Exploring the effects of artificial intelligence on student and academic well-being in higher education: a mini-review. *Front Psychol.* 2025;16:1498132. doi:10.3389/fpsyg.2025.1498132.
12. Laak KJ, Aru J. AI and personalized learning: bridging the gap with modern educational goals. Published online March 21, 2025. doi:10.48550/arXiv.2404.02798.
13. Lu Y, Chen C, Chen Y, Huang K, Zitnik M, Wang Q. GNN 101: Visual Learning of Graph Neural Networks in Your Web Browser. *arXiv.org*. November 26, 2024. Accessed June 9, 2025. <https://arxiv.org/abs/2411.17849v3>.
14. Luan H, Geczy P, Lai H, et al. Challenges and Future Directions of Big Data and Artificial Intelligence in Education. *Front Psychol.* 2020;11:580820. doi:10.3389/fpsyg.2020.580820.
15. Motlagh NY, Khajavi M, Sharifi A, Ahmadi M. The Impact of Artificial Intelligence on the Evolution of Digital Education: A Comparative Study of OpenAI Text Generation Tools including ChatGPT, Bing Chat, Bard, and Ernie. Published online May 19, 2025. doi:10.48550/arXiv.2309.02029.
16. Sastry G, Heim L, Belfield H, et al. Computing Power and the Governance of Artificial Intelligence. *arXiv.org*. February 13, 2024. Accessed June 9, 2025. <https://arxiv.org/abs/2402.08797v1>.
17. Scarfe P, Watcham K, Clarke A, Roesch E. A real-world test of artificial intelligence infiltration of a university examinations system: A "Turing Test" case study. *PLoS One.* 2024;19(6):e0305354. doi:10.1371/journal.pone.0305354
18. Shiri FM, Perumal T, Mustapha N, Mohamed R. A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU. *arXiv.org*. doi:10.32604/jai.2024.054314.
19. Tian Y, Xia F, Song Y. Large Language Models Are No Longer Shallow Parsers. In: Ku LW, Martins A, Srikumar V, eds. *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*. Association for Computational Linguistics; 2024:7131-7142. doi:10.18653/v1/2024.acl-long.384.
20. Wang ZJ, Turko R, Shaikh O, et al. CNN 101: Interactive Visual Learning for Convolutional Neural Networks. In: *Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems*. CHI EA '20. Association for Computing Machinery; 2020:1-7. doi:10.1145/3334480.3382899.
21. Wang ZJ, Turko R, Shaikh O, et al. CNN Explainer: Learning Convolutional Neural Networks with Interactive Visualization. *arXiv.org*. doi:10.1109/TVCG.2020.3030418.