O'REILLY®

Przetwarzanie języka naturalnego w praktyce

Przewodnik po budowie rzeczywistych systemów NLP

Sowmya Vajjala
Bodhisattwa Majumder
Anuj Gupta
Harshit Surana

Helion

Tytuł oryginału: Practical Natural Language Processing:
A Comprehensive Guide to Building Real-World NLP Systems

Tłumaczenie: Grzegorz Werner

ISBN: 978-83-8322-726-9

Drogi Czytelniku!
Jeżeli chcesz ocenić tę książkę, zajrzyj pod adres
https://helion.pl/user/opinie/przjen
Możesz tam wpisać swoje uwagi, spostrzeżenia, recenzję.

Helion S.A.
ul. Kościuszki 1c, 44-100 Gliwice
tel. 32 230 98 63
e-mail: *helion@helion.pl*
WWW: *https://helion.pl* (księgarnia internetowa, katalog książek)

Printed in Poland.

Spis treści

ROZDZIAŁ 1.
NLP — elementarz

Język to nie tylko słowa. To kultura, tradycja, jednoczenie społeczności,
cała historia, która określa, czym społeczność jest.
Wszystko to jest odzwierciedlone w języku.

— Noam Chomsky

Wyobraź sobie hipotetyczną osobę, Jana Kowalskiego. Jest on dyrektorem ds. technologii w szybko rozwijającym się start-upie. Pewnego dnia Jan budzi się i odbywa następującą rozmowę ze swoim asystentem cyfrowym:

Jan: „Jaka jest dziś pogoda?".

Asystent cyfrowy: „Na zewnątrz jest 27 stopni i nie pada".

Jan: „Jakie są moje plany na dziś?".

Asystent cyfrowy: „Masz zebranie strategiczne o 16.00 i konferencję o 17.30. Zważywszy na sytuację na drogach, powinieneś wyjechać do biura najpóźniej o 8.15".

Kiedy Jan się ubiera, pyta swojego asystenta o dobór ubrań.

Jan: „Co powinienem dziś założyć?".

Asystent cyfrowy: „Biały wydaje się dobrym pomysłem".

Być może prowadziłeś podobne rozmowy z inteligentnymi asystentami, takimi jak Amazon Alexa, Google Home lub Apple Siri. Mówimy do nich nie w języku programowania, ale w języku naturalnym — tym, w którym komunikujemy się na co dzień. Język naturalny jest podstawowym środkiem komunikacji między ludźmi od niepamiętnych czasów. Komputery jednak przetwarzają tylko dane binarne, tzn. zera i jedynki. Choć możemy reprezentować dane językowe w postaci binarnej, jak sprawić, żeby maszyny rozumiały język? Tu na scenę wkracza przetwarzanie języka naturalnego (ang. *natural language processing* — NLP). Jest to dziedzina informatyki zajmująca się metodami analizowania, modelowania i rozumienia ludzkiego języka. Każda inteligentna aplikacja sterowana ludzkim językiem wykorzystuje jakąś postać NLP. W tej książce wyjaśnimy, czym jest NLP i jak używać go do budowania i skalowania inteligentnych aplikacji. Ze względu na otwartą naturę problemów NLP istnieją dziesiątki alternatywnych rozwiązań każdego problemu. Ta książka pomoże Ci poruszać się po labiryncie dostępnych opcji i wybrać tę, która najlepiej pasuje do danego problemu.

Celem tego rozdziału jest krótkie omówienie NLP, zanim zaczniemy zagłębiać się w praktyczną implementację rozwiązań opartych na NLP. Zaczniemy od przeglądu licznych aplikacji NLP w rzeczywistych scenariuszach, a następnie omówimy różne zadania, które stanowią podstawę budowania aplikacji NLP. Potem spróbujemy zrozumieć język z perspektywy NLP i wyjaśnić, dlaczego NLP jest trudne. Następnie powiemy kilka słów o heurystyce, uczeniu maszynowym i uczeniu głębokim, po czym przedstawimy kilka algorytmów powszechnie używanych w NLP. Wreszcie opiszemy elementy typowej aplikacji NLP. Rozdział zakończymy przeglądem pozostałych tematów z książki. Na rysunku 1.1 pokazano organizację rozdziałów według rozmaitych zadań i zastosowań NLP.

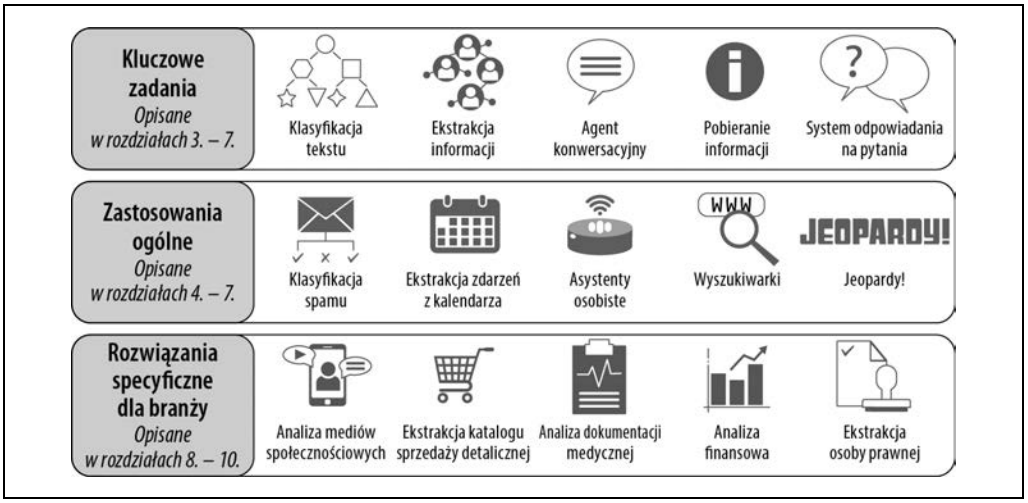

Rysunek 1.1. Zadania i zastosowania NLP

Zacznijmy od przyjrzenia się popularnym aplikacjom, których używamy na co dzień i których istotnym składnikiem jest jakaś forma NLP.

NLP w rzeczywistym świecie

NLP jest istotnym składnikiem licznych aplikacji, których używamy w codziennym życiu. W tym podrozdziale przedstawimy niektóre kluczowe aplikacje i przyjrzymy się typowym zadaniom realizowanym przez różnorodne aplikacje NLP. Wspomnimy o zastosowaniach pokazanych na rysunku 1.1, które zostaną opisane dokładniej dalej w tej książce.

Kluczowe zastosowania:

- Platformy e-mail, np. Gmail, Outlook, wykorzystują NLP do realizowania różnych funkcji, takich jak klasyfikacja spamu, umieszczanie wiadomości w skrzynce priorytetowej, ekstrakcja zdarzeń kalendarzowych, autouzupełnianie itd. Niektóre z tych funkcji omówimy szczegółowo w rozdziałach 4. i 5.
- Asystenty głosowe, takie jak Apple Siri, Google Assistant, Microsoft Cortana i Amazon Alexa, wykorzystują różne techniki NLP do interakcji z użytkownikiem, rozpoznawania poleceń

użytkownika i odpowiedniego reagowania na nie. Kluczowe aspekty takich systemów opiszemy w rozdziale 6., kiedy będziemy mówić o czatbotach.

- Współczesne wyszukiwarki, takie jak Google i Bing, które są podstawą dzisiejszego internetu, intensywnie wykorzystują NLP do różnych podzadań, takich jak rozpoznawanie zapytań, rozwijanie zapytań, odpowiadanie na pytania, wyszukiwanie informacji oraz klasyfikowanie i grupowanie wyników. Niektóre z tych podzadań omówimy w rozdziale 7.
- Usługi tłumaczenia maszynowego, takie jak Google Translate, Bing Microsoft Translator i Amazon Translate, są coraz powszechniej wykorzystywane w życiu codziennym i scenariuszach biznesowych. O tłumaczeniu maszynowym wspomnimy w rozdziale 7.

Inne zastosowania:

- Organizacje z różnych branż analizują swoje kanały społecznościowe, aby lepiej wsłuchiwać się w głos klienta. Omówimy to w rozdziale 8.
- NLP używa się do rozwiązywania wielu różnorodnych problemów na platformach e-commerce, takich jak Amazon, od ekstrahowania istotnych informacji z opisów produktów do rozumienia recenzji użytkowników. Zostanie to opisane szczegółowo w rozdziale 9.
- Postępy w NLP wykorzystuje się do rozwiązywania problemów w takich dziedzinach jak opieka zdrowotna, finanse i prawo. Będzie to tematem rozdziału 10.
- Firmy takie jak Arria [1] pracują nad technikami NLP do automatycznego generowania raportów w różnych dziedzinach, od prognozowania pogody do usług finansowych.
- NLP jest kluczowym elementem narzędzi do sprawdzania gramatyki i pisowni, takich jak usługa Grammarly oraz sprawdzanie pisowni w programach Microsoft Word i Google Docs.
- *Jeopardy!* to popularny teleturniej (w Polsce znany jako Va banque). Uczestnicy otrzymują wskazówki w formie haseł i udzielają odpowiedzi sformułowanych jako pytania. Firma IBM zbudowała system Watson AI, aby konkurował z najlepszymi graczami. Watson zdobył pierwszą nagrodę w wysokości miliona dolarów, więcej niż mistrz świata. Został zbudowany z wykorzystaniem technik NLP i jest przykładem bota NLP, który wygrał mistrzostwa świata.
- NLP używa się w różnych narzędziach i technologiach edukacyjnych oraz oceniających, np.: w systemach automatycznego oceniania egzaminów takich jak Graduate Record Examination (GRE), w systemach wykrywania plagiatów (np. Turnitin), w inteligentnych systemach nauczania oraz w aplikacjach do nauki języków takich jak Duolingo.
- NLP używa się do budowania dużych baz wiedzy, takich jak Google Knowledge Graph, które przydają się do wyszukiwania informacji i odpowiadania na pytania.

Lista ta nie jest bynajmniej wyczerpująca. NLP coraz częściej używa się do innych celów, a kiedy piszę te słowa, nieustannie pojawiają się nowe zastosowania NLP. My skupimy się przede wszystkim na ideach stojących za tymi aplikacjami. Aby pokazać Ci, czego dowiesz się z tej książki, i przedstawić niuanse związane z tworzeniem oprogramowania NLP, opiszemy niektóre kluczowe zadania NLP, które stanowią podstawę wielu aplikacji i zastosowań branżowych.

Zadania NLP

Istnieje zbiór podstawowych zadań, które pojawiają się często w różnych projektach NLP. Ze względu na ich powtarzalną i fundamentalną naturę zostały one szczegółowo zbadane. Ich dobre zrozumienie przygotuje Cię do budowania aplikacji NLP dla różnych branż. (Niektóre pokazaliśmy wcześniej na rysunku 1.1). Oto ich krótki opis:

Modelowanie językowe

Zadanie to polega na przewidywaniu, jakie będzie następne słowo w zdaniu, na podstawie poprzednich słów. Celem tego zadania jest określenie prawdopodobieństwa sekwencji słów występujących w danym języku. Modelowanie językowe przydaje się w rozwiązywaniu wielu problemów, takich jak rozpoznawanie mowy, optyczne rozpoznawanie znaków, rozpoznawanie pisma ręcznego, tłumaczenie maszynowe i sprawdzanie pisowni.

Klasyfikacja tekstu

To zadanie polega na przypisywaniu tekstu do określonej kategorii na podstawie jego treści. Klasyfikacja tekstu jest zdecydowanie najpopularniejszym zadaniem w NLP i używa się jej w różnych narzędziach, od identyfikowania spamu do analizowania odczuć.

Ekstrakcja informacji

Jak wskazuje nazwa, zadanie to polega na wyodrębnianiu z tekstu istotnych informacji, np. zdarzeń kalendarzowych z wiadomości e-mail albo nazwisk osób wspomnianych w poście w mediach społecznościowych.

Pobieranie informacji

To zadanie polega na znajdowaniu dokumentów związanych z kwerendą użytkownika. Dobrze znanymi zastosowaniami pobierania informacji są takie aplikacje jak wyszukiwarka Google.

Agent konwersacyjny

To zadanie polega na budowaniu systemów dialogowych, które mogą prowadzić rozmowę w ludzkim języku. Typowymi zastosowaniami tego zadania są Alexa, Siri itp.

Streszczanie tekstu

To zadanie polega na tworzeniu krótkich streszczeń dłuższych dokumentów przy zachowaniu zasadniczej treści i ogólnego znaczenia tekstu.

Odpowiadanie na pytania

To zadanie polega na budowaniu systemu, który może automatycznie odpowiadać na pytania zadawane w języku naturalnym.

Tłumaczenie maszynowe

To zadanie polega na przekładaniu tekstu z jednego języka na drugi. Typowym zastosowaniem tego zadania są takie narzędzia jak Google Translate.

Modelowanie tematyczne

To zadanie polega na określaniu tematycznej struktury dużego zbioru dokumentów. Modelowanie tematyczne to popularne narzędzie „wydobywcze" używane w wielu dziedzinach, od literatury do bioinformatyki.

Na rysunku 1.2 przedstawiono te zadania według względnej trudności opracowywania kompleksowych rozwiązań.

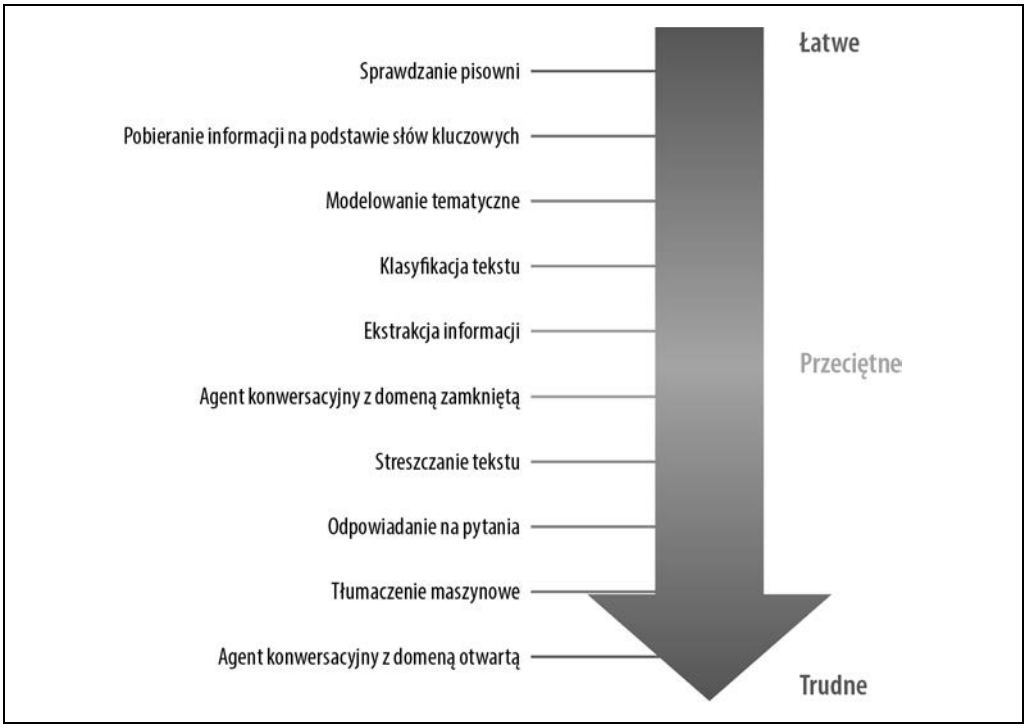

Rysunek 1.2. Zadania NLP ułożone według względnego stopnia trudności

W pozostałych rozdziałach książki poznasz wyzwania, które wiążą się z tymi zadaniami, i nauczysz się tworzyć rozwiązania, które skutecznie działają w pewnych sytuacjach (nawet w przypadku trudnych zadań pokazanych na rysunku). Aby osiągnąć ten cel, trzeba zrozumieć naturę ludzkiego języka i problemy związane z automatycznym przetwarzaniem języka. Zagadnienia te zostaną krótko opisane w następnych dwóch podrozdziałach.

Czym jest język?

Język to ustrukturyzowany system komunikacji, który wykorzystuje skomplikowane kombinacje elementów składowych, takich jak znaki, słowa, zdania itd. Systematyczne badanie języka określa się mianem lingwistyki. Aby badać NLP, trzeba zrozumieć niektóre pojęcia lingwistyczne dotyczące struktury języka. W tym podrozdziale przedstawimy je i wyjaśnimy, jak wiążą się z niektórymi wspomnianymi wcześniej zadaniami NLP.

Możemy myśleć o języku jako o tworze złożonym z czterech podstawowych elementów: fonemów, morfemów i leksemów, składni oraz kontekstu. Aplikacje NLP wymagają znajomości różnych poziomów tych elementów, od podstawowych dźwięków języka (fonemów) do tekstów wyrażających pewien sens (kontekstu).

Na rysunku 1.3 pokazano podstawowe elementy języka, ich zakres i kilka wspomnianych wcześniej aplikacji NLP, które wymagają tej wiedzy. Niektóre użyte terminy, których nie wprowadzono wcześniej w tym rozdziale (np. analiza składniowa, osadzenia słów), zostaną wyjaśnione w kolejnych rozdziałach.

Rysunek 1.3. Podstawowe elementy języka i ich zastosowania

Podstawowe elementy języka

Opiszmy najpierw, czym są poszczególne elementy języka, aby przedstawić kontekst wyzwań związanych z NLP.

Fonemy

Fonemy to najmniejsze jednostki dźwiękowe języka. Same w sobie mogą nie mieć żadnego znaczenia, ale tworzą znaczenie, kiedy zostaną wypowiedziane w kombinacji z innymi fonemami. Na przykład standardowy język angielski ma 44 fonemy reprezentowane albo przez pojedyncze litery, albo przez kombinacje liter [2]. Na rysunku 1.4 pokazano te fonemy wraz z przykładowymi słowami. Fonemy są szczególnie istotne w aplikacjach, które wymagają rozumienia mowy, takich jak rozpoznawanie mowy, transkrypcja mowy i przekształcanie tekstu na mowę.

Morfemy i leksemy

Morfem to najmniejsza jednostka języka, która ma znaczenie. Morfemy powstają z połączenia fonemów. Nie wszystkie morfemy są słowami, ale wszystkie przedrostki i przyrostki są morfemami. Na przykład w słowie „multimedia" „multi-" nie jest słowem, ale przedrostkiem, który zmienia znaczenie słowa „media". „Multi-" to morfem. Na rysunku 1.5 pokazano kilka słów i ich morfemy. W słowach takich jak „cats" i „unbreakable" poszczególne morfemy łączą się ze sobą bez żadnych zmian, natomiast w słowach takich jak „tumbling" i „unreliability" ulegają pewnym przekształceniom.

Fonemy spółgłoskowe z przykładowymi słowami		Fonemy samogłoskowe z przykładowymi słowami	
1. /b/ – bat	13. /s/ – sun	1. /a/ – ant	13. /oi/ – coin
2. /k/ – cat	14. /t/ – tap	2. /e/ – egg	14. /ar/ – farm
3. /d/ – dog	15. /v/ – van	3. /i/ – in	15. /or/ – for
4. /f/ – fan	16. /w/ – wig	4. /o/ – on	16. /ur/ – hurt
5. /g/ – go	17. /y/ – yes	5. /u/ – up	17. /air/ – fair
6. /h/ – hen	18. /z/ – zip	6. /ai/ – rain	18. /ear/ – dear
7. /j/ – jet	19. /sh/ – shop	7. /ee/ – feet	19. /ure/ – sure
8. /l/ – leg	20. /ch/ – chip	8. /igh/ – night	20. /ə/ – corner („schwa" – nieakcentowana samogłoska o brzmieniu zbliżonym do /u/)
9. /m/ – map	21. /th/ – thin	9. /oa/ – boat	
10. /n/ – net	22. /**th**/ – then	10. /**oo**/ – boot	
11. /p/ – pen	23. /ng/ – ring	11. /oo/ – look	
12. /r/ – rat	24. /zh/ – vision	12. /ow/ – cow	

Rysunek 1.4. Fonemy i przykładowe słowa

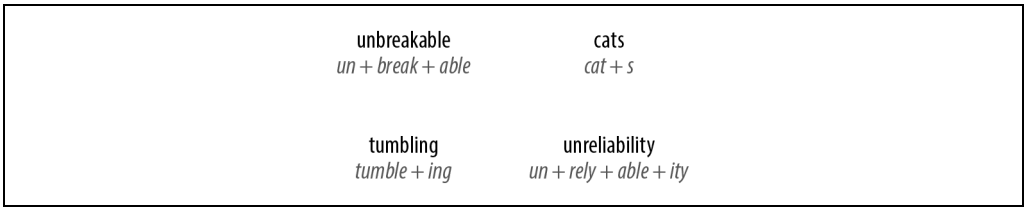

Rysunek 1.5. Przykładowe morfemy

Leksemy to strukturalne odmiany morfemów, które są powiązane znaczeniowo. Na przykład „run" i „running" należą do tej samej formy leksemowej. Analiza morfologiczna, która bada strukturę słów poprzez wyodrębnianie morfemów i leksemów, stanowi fundament wielu zadań NLP, takich jak tokenizacja, określanie tematów słów, nauka osadzeń słów i tagowanie części mowy, które zostaną przedstawione w następnym rozdziale.

Składnia

Składnia to zbiór reguł, które umożliwiają konstruowanie poprawnych gramatycznie zdań ze słów i z fraz danego języka. W lingwistyce istnieje wiele sposobów reprezentowania struktury składniowej. Często przedstawia się ją w postaci drzewa składniowego. Na rysunku 1.6 pokazano przykładowe drzewo składniowe dwóch angielskich zdań.

Drzewo odzwierciedla hierarchiczną strukturę języka ze słowami na najniższym poziomie, po których następują tagi części mowy, dalej frazy, a wreszcie zdanie na najwyższym poziomie. Zdania z rysunku 1.6 mają podobną strukturę składniową, a zatem podobne drzewo składniowe. W tej reprezentacji N

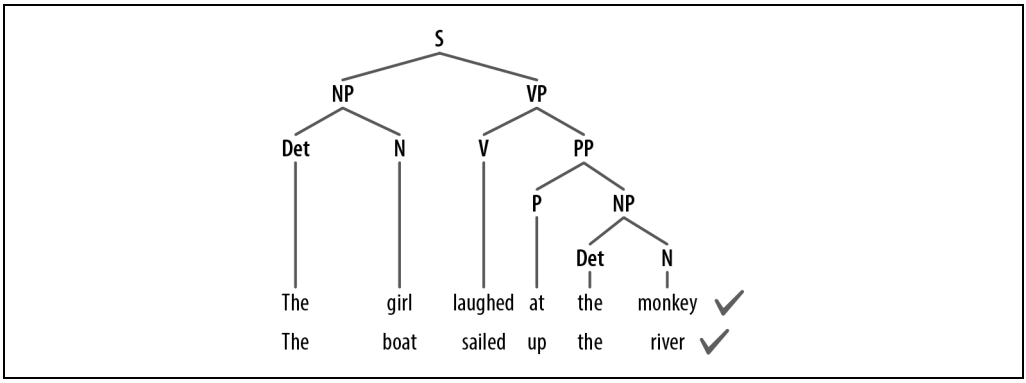

Rysunek 1.6. Struktura dwóch podobnych składniowo zdań

oznacza rzeczownik (ang. *noun*), V — czasownik (ang. *verb*), a P — przyimek (ang. *preposition*). Fraza nominalna (rzeczownikowa) jest oznaczona przez NP (ang. *noun phrase*), a fraza werbalna (czasownikowa) — przez VP (ang. *verb phrase*). Dwie frazy nominalne to „The girl" i „The boat", a dwie frazy werbalne to „laughed at the monkey" i „sailed up the river". Struktura składniowa podlega regułom gramatycznym języka (np. „Zdanie składa się z NP i VP"), a te z kolei wpływają na niektóre fundamentalne zadania przetwarzania języka, takie jak analiza składniowa, zwana również parsowaniem. Parsowanie to zadanie NLP polegające na automatycznym konstruowaniu takich drzew. Wykorzystuje się je m.in. do ekstrakcji encji i ekstrakcji relacji — zadań NLP, które omówimy dokładniej w rozdziale 5. Zauważ, że opisana wyżej struktura składniowa jest specyficzna dla języka angielskiego. Składnia jednego języka może się bardzo różnić od składni drugiego, dlatego sposoby przetwarzania tych języków bywają odmienne.

Kontekst

Kontekst określa, jak różne części języka łączą się ze sobą w celu przekazania jakiegoś znaczenia. Kontekst obejmuje odniesienia długoterminowe, wiedzę o świecie i zdrowy rozsądek obok dosłownego znaczenia słów i fraz. Sens zdania może się zmieniać w zależności od kontekstu, ponieważ słowa i frazy czasem mają wiele znaczeń. Ogólnie rzecz biorąc, kontekst obejmuje semantykę i pragmatykę. Semantyka to bezpośrednie znaczenie słów i fraz wyjętych z zewnętrznego kontekstu. Pragmatyka dodaje wiedzę o świecie i kontekst zewnętrzny, pozwalając nam domyślić się podtekstu. Złożone zastosowania NLP, takie jak wykrywanie sarkazmu, streszczanie i modelowanie tematyczne, to przykłady zadań, które intensywnie używają kontekstu.

Lingwistyka to nauka o języku, a zatem bardzo rozległa dziedzina, a my przedstawiliśmy tylko kilka podstawowych pojęć, aby zilustrować rolę wiedzy lingwistycznej w NLP. Różne zadania NLP wymagają różnego stopnia wiedzy o tych podstawowych elementach budulcowych języka. Zainteresowany czytelnik może sięgnąć po książki Emily Bender [3, 4] poświęcone lingwistyce w NLP. Teraz, kiedy wiemy już, z czego składa się język, zastanówmy się, dlaczego komputery mają problemy ze zrozumieniem języka i co sprawia, że NLP jest trudnym wyzwaniem.

Dlaczego NLP jest trudnym wyzwaniem?

Co sprawia, że NLP jest trudnym wyzwaniem? Między innymi wieloznaczność i kreatywność ludzkiego języka. W tym punkcie zbadamy bliżej te cechy, zaczynając od wieloznaczności.

Wieloznaczność

Większość ludzkich języków jest z natury niejednoznaczna. Rozważ następujące angielskie zdanie: „I made her duck". Ma ono wiele znaczeń. Pierwsze to: „Ugotowałem dla niej kaczkę". Drugie to: „Zmusiłem ją do schylenia się w celu uniknięcia uderzenia przez lecący przedmiot". (Istnieją też inne możliwe znaczenia; pozostawiamy je do wymyślenia czytelnikowi). Wieloznaczność wynika tu z użycia słowa „made". To, które z tych dwóch znaczeń jest właściwe, zależy od kontekstu, w jakim wypowiedziano zdanie. Jeśli zdanie pojawia się w opowiadaniu o matce i dziecku, prawdopodobnie chodzi o pierwsze znaczenie. Ale jeśli pojawia się w książce o sporcie, prawdopodobnie chodzi o drugie znaczenie. Przykład, który widzieliśmy, to zdanie bezpośrednie.

Jeśli chodzi o język figuratywny — tzn. idiomy — wieloznaczność jest jeszcze większa. Na przykład: „He is as good as John Doe". Jak dobry jest ten, o kim mowa? Odpowiedź zależy od tego, jak dobry jest John Doe. Na rysunku 1.7 przedstawiono kilka przykładów ilustrujących wieloznaczność języka.

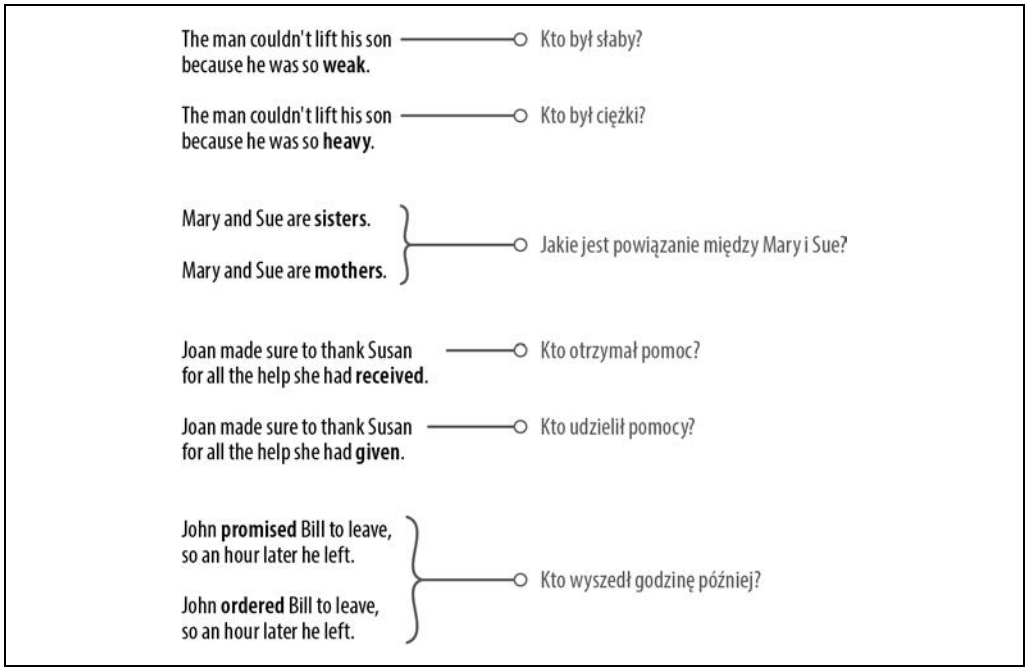

Rysunek 1.7. Przykłady wieloznaczności języka zaczerpnięte z Winograd Schema Challenge

Przykłady pochodzą z zestawu testów Winograd Schema Challenge [5] nazwanego tak na cześć profesora Terry'ego Winograda z Uniwersytetu Stanforda. W zestawie tym znajdują się pary zdań, które różnią się tylko kilkoma słowami, ale zmiany te często powodują odwrócenie znaczenia. Przykłady te

są zrozumiałe dla ludzi, ale nie można ich rozwiązać z użyciem większości technik NLP. Przyjrzyj się parom zdań na rysunku i związanym z nimi pytaniom. To, jak zmienia się odpowiedź wskutek zmiany jednego słowa, powinno być oczywiste. W ramach innego eksperymentu możesz skorzystać z jakiegoś gotowego systemu NLP, takiego jak Google Translate, aby sprawdzić, jak wieloznaczność wpływa (lub nie wpływa) na generowane wyniki.

Powszechna wiedza

Kluczowym aspektem każdego ludzkiego języka jest „powszechna wiedza". To zbiór wszystkich faktów, które są znane większości ludzi. Podczas każdej konwersacji zakłada się, że fakty te są znane rozmówcom, więc nie wspomina się o nich jawnie, ale mają one wpływ na znaczenie zdań. Rozważ dwa zdania: „Człowiek ugryzł psa" i „Pies ugryzł człowieka". Wiemy, że sytuacja z pierwszego zdania raczej się nie zdarzyła, a ta druga jest bardzo prawdopodobna. Dlaczego? Ponieważ wiadomo, że ludzie zwykle nie gryzą psów, wiadomo też, że psy często gryzą ludzi. Wiedza ta jest nam potrzebna, żeby orzec, że pierwsze zdanie zapewne jest fałszywe, a drugie prawdziwe. Zauważ jednak, że ta powszechna wiedza nie została wspomniana w żadnym zdaniu. Ludzie nieustannie wykorzystują powszechną wiedzę do rozumienia i przetwarzania języka. W powyższym przykładzie dwa zdania są bardzo podobne składniowo i komputer miałby problem z ich rozróżnieniem, gdyż brakuje mu powszechnej wiedzy, którą mają ludzie. Jednym z kluczowych wyzwań NLP jest zakodowanie powszechnej ludzkiej wiedzy w modelu komputerowym.

Kreatywność

Język to nie tylko reguły; ma on również aspekt kreatywny. W każdym języku używa się różnych stylów, dialektów, rejestrów i odmian. Doskonałym przykładem kreatywności w języku są wiersze. Sprawienie, żeby maszyny rozumiały kreatywność, to trudny problem nie tylko w NLP, ale w ogóle w dziedzinie sztucznej inteligencji.

Różnorodność języków

W przypadku większości języków świata nie ma bezpośredniego odwzorowania między ich słownikami. Utrudnia to przenoszenie rozwiązań NLP między językami. Rozwiązanie, które działa dobrze w jednym języku, może w ogóle nie działać w drugim. Oznacza to, że trzeba albo zbudować rozwiązanie neutralne językowo, albo budować oddzielnie rozwiązania dla każdego języka. To pierwsze jest trudne koncepcyjnie, to drugie pochłania mnóstwo pracy i czasu.

Wszystkie te problemy sprawiają, że praca z NLP jest bardzo trudna, choć satysfakcjonująca. Zanim pokażemy, jak NLP radzi sobie z tymi wyzwaniami, powinieneś poznać typowe podejścia do rozwiązywania problemów NLP. Zaczniemy od omówienia związków uczenia maszynowego i uczenia głębokiego z NLP, a następnie przyjrzymy się różnym podejściom do NLP.

Uczenie maszynowe, uczenie głębokie i NLP — przegląd

Mówiąc nieformalnie, sztuczna inteligencja (ang. *artificial intelligence* — AI) to gałąź informatyki, która zajmuje się budowaniem systemów zdolnych do wykonywania zadań wymagających ludzkiej inteligencji. Fundamenty AI utworzono w latach 50. ubiegłego wieku podczas warsztatów

zorganizowanych w Dartmouth College [6]. Początkowo AI budowano głównie z systemów opartych na logice, heurystyce i regułach. Uczenie maszynowe (ang. *machine learning* — ML) to odnoga AI zajmująca się opracowywaniem algorytmów, które uczą się wykonywać zadania na podstawie dużej liczby przykładów, bez ręcznego kodowania reguł. Uczenie głębokie (ang. *deep learning* — DL) to odmiana uczenia maszynowego wykorzystująca sztuczne sieci neuronowe. ML, DL i NLP to poddziedziny AI, a ich wzajemne relacje zilustrowano na rysunku 1.8.

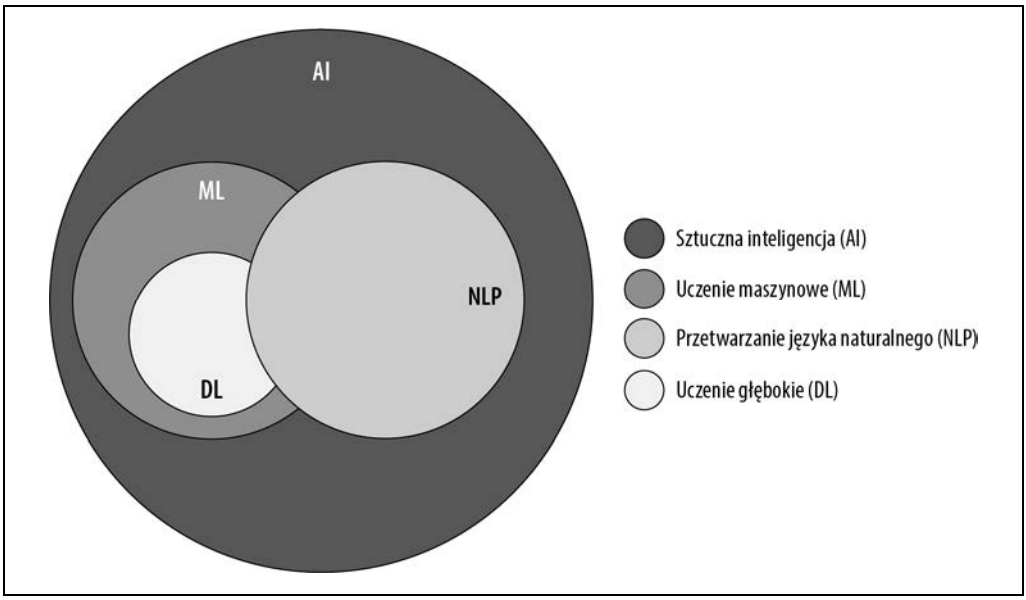

Rysunek 1.8. Relacje między NLP, ML i DL

Choć dziedziny NLP, ML i DL częściowo się nakładają, są to różne obszary badań, jak pokazuje rysunek. Podobnie jak inne wczesne prace AI, pierwsze aplikacje NLP również były oparte na regułach i heurystyce. Jednak w ciągu ostatnich dziesięcioleci do tworzenia aplikacji NLP zaczęto używać metod ML. W związku z tym warto powiedzieć tu kilka słów o ML i DL.

Celem systemów ML jest „uczenie się" wykonywania zadań na podstawie przykładów (zwanych danymi treningowymi) bez jasno sprecyzowanych instrukcji. Zwykle robi się to poprzez utworzenie liczbowej reprezentacji (zwanej cechami) danych treningowych i wykorzystanie tej reprezentacji do nauczenia systemu wzorców zawartych w danych. Algorytmy uczenia maszynowego można podzielić na trzy podstawowe paradygmaty: uczenie nadzorowane (ang. *supervised learning*), uczenie nienadzorowane (ang. *unsupervised learning*) i uczenie ze wzmocnieniem (ang. *reinforcement learning*). W uczeniu nadzorowanym celem jest nauczenie się funkcji odwzorowywania wejścia na wyjście na podstawie dużej liczby przykładów w postaci par wejście – wyjście. Pary wejście – wyjście są znane jako **dane treningowe**, a same wyjścia określa się mianem **etykiet** lub **prawdy podstawowej** (ang. *ground truth*). Przykładem problemu uczenia nadzorowanego jest nauka klasyfikowania wiadomości e-mail jako spamu lub nie spamu na podstawie tysięcy przykładów z obu kategorii. Jest to typowy scenariusz w NLP, a w tej książce znajdziesz wiele przykładów uczenia nadzorowanego, zwłaszcza w rozdziale 4.

Uczenie nienadzorowane to metody uczenia maszynowego, które mają na celu znajdowanie ukrytych wzorców w danych wejściowych bez żadnych wyjściowych danych odniesienia. To znaczy, że — w przeciwieństwie do uczenia nadzorowanego — uczenie nienadzorowane działa na dużych zbiorach nieoznakowanych danych. W NLP przykładem takiego zadania jest identyfikowanie tematów w dużych zbiorach danych tekstowych bez żadnej uprzedniej wiedzy o tych tematach. Jest to tzw. **modelowanie tematyczne**, które omówimy w rozdziale 7.

W rzeczywistych projektach NLP często używa się uczenia półnadzorowanego, w którym mamy niewielki zbiór etykietowanych danych i duży zbiór danych bez etykiet. Techniki półnadzorowane wiążą się z użyciem obu zbiorów danych w celu nauczenia systemu danego zadania. Wreszcie uczenie ze wzmocnieniem polega na uczeniu systemu metodą prób i błędów i cechuje się brakiem dużej ilości danych czy to z etykietami, czy bez nich. Nauka odbywa się w izolowanym środowisku, a postępy osiąga się poprzez informacje zwrotne (nagrody lub kary). Ta odmiana uczenia nie jest (jeszcze) często spotykana w praktycznych systemach NLP. Częściej widuje się ją w takich zastosowaniach jak komputerowe szachy lub go, projektowanie pojazdów autonomicznych i robotyka.

Uczenie głębokie to uczenie maszynowe oparte na sztucznych sieciach neuronowych. Inspiracją do powstania sieci neuronowych były neurony w ludzkim mózgu i ich wzajemne interakcje. W minionej dekadzie architektury neuronowe oparte na uczeniu głębokim wykorzystano do ulepszenia wielu inteligentnych aplikacji, takich jak rozpoznawanie obrazów i mowy oraz tłumaczenie maszynowe. Dlatego w branży pojawiło się wiele rozwiązań opartych na uczeniu głębokim, w tym aplikacje NLP.

W naszej książce wyjaśnimy, jak wykorzystuje się wszystkie te sposoby do tworzenia różnych aplikacji NLP. Opiszmy teraz różne podejścia do rozwiązywania problemów NLP.

Podejścia do NLP

Sposoby rozwiązywania problemów NLP można podzielić na trzy kategorie: heurystyka, uczenie maszynowe i uczenie głębokie. Ten podrozdział jest krótkim wprowadzeniem do każdego podejścia — nie martw się, jeśli w pełni nie zrozumiesz wspomnianych tu koncepcji, ponieważ zostaną one opisane szczegółowo dalej w książce. Zacznijmy od omówienia NLP opartego na heurystyce.

NLP oparte na heurystyce

Podobnie jak inne wczesne systemy AI, pierwsze systemy NLP realizowały swoje zadania na podstawie reguł. Deweloperzy musieli zatem mieć specjalistyczną wiedzę w danej dziedzinie, aby sformułować reguły dołączane do programu. Systemy te wymagały również takich zasobów jak słowniki i tezaurusy, zwykle kompilowanych i przekształcanych w postać cyfrową w dłuższych okresach. Przykładem projektowania reguł w celu rozwiązania problemu NLP z wykorzystaniem takich zasobów jest analiza odczuć oparta na leksykonie. Opiszemy ją krótko w rozdziale 4.

Oprócz słowników i tezaurusów tworzono również bardziej rozbudowane bazy wiedzy do wspomagania NLP, zwłaszcza NLP opartego na regułach. Przykładem jest WordNet [7], baza słów i semantycznych relacji między nimi. Przykładami takich relacji są synonimy, hiponimy i meronimy. Synonimy to słowa o podobnym znaczeniu. Hiponimy reprezentują relację „jest typem czegoś”,

np. bejsbol, sumo i tenis to hiponimy sportu. Meronimy reprezentują relację „jest częścią czegoś”, np. ręce i nogi to meronimy ciała. Wszystkie te informacje przydają się podczas budowania systemów przetwarzania języka na podstawie reguł. Na rysunku 1.9 pokazano graficzną reprezentację takich relacji między słowami w bazie WordNet.

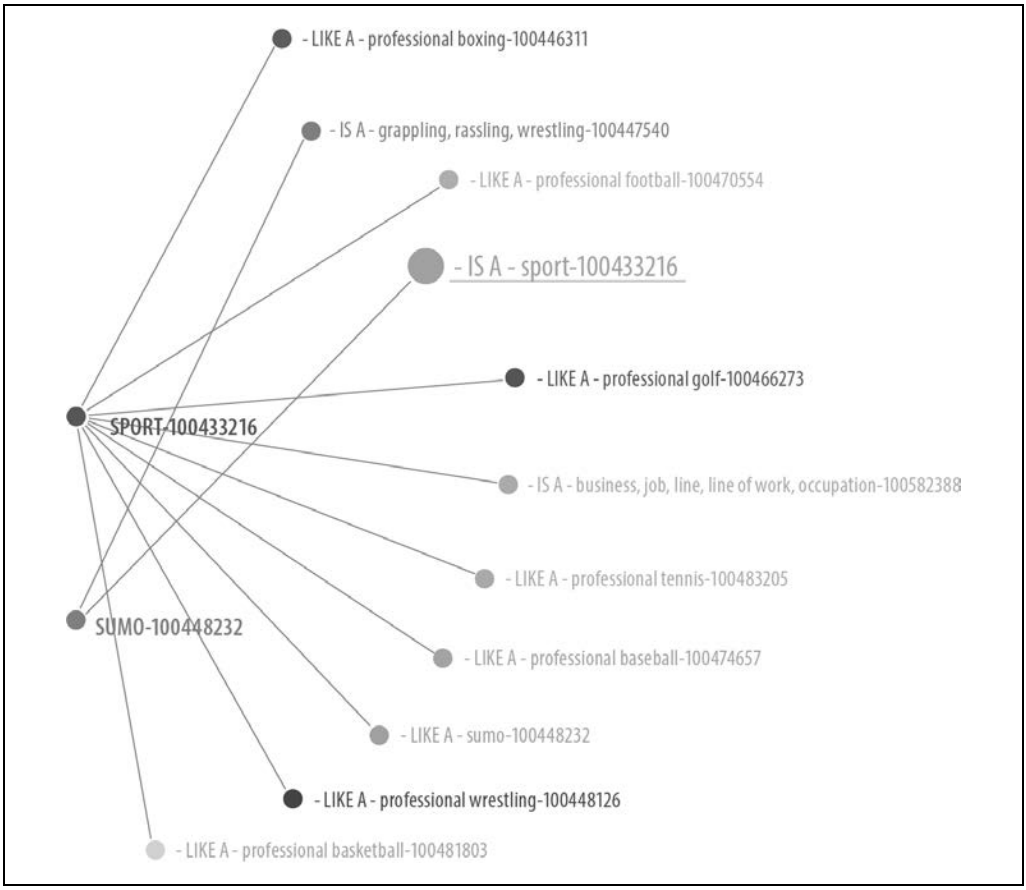

Rysunek 1.9. Graf bazy WordNet dla słowa „sport” [8]

Od niedawna do baz wiedzy takich jak Open Mind Common Sense [9] dodaje się także „zdroworozsądkową” wiedzę o świecie, co również wspomaga systemy oparte na regułach. Choć do tej pory mówiliśmy głównie o zasobach leksykalnych w postaci słów, systemy oparte na regułach mogą wykraczać poza słowa i wykorzystywać inne formy informacji. Niektóre z nich przedstawiono poniżej.

Wyrażenia regularne („regeksy”) to znakomite narzędzie do analizowania tekstu i budowania systemów opartych na regułach. Regex to zbiór znaków albo wzorzec używany do dopasowywania i wyszukiwania podłańcuchów w tekście. Na przykład regex „^([a-zA-Z0-9_\-\.]+)@([a-zA-Z0-9_\-\.]
➥+)\.([a-zA-Z]{2,5})$” pozwala znaleźć adresy e-mail w pewnym fragmencie tekstu. Regeksy są doskonałym sposobem dodawania wiedzy dziedzinowej do systemu NLP. Na przykład mamy skargi klientów zgłaszane za pośrednictwem czatu lub poczty e-mail i chcemy zbudować system

automatycznie identyfikujący produkt, którego dotyczy skarga. Istnieje zbiór kodów produktów, które można odwzorować na określone nazwy marek. Aby je dopasowywać, możemy użyć wyrażeń regularnych.

Regeksy to bardzo popularny paradygmat budowania systemów opartych na regułach. Na przykład oprogramowanie StanfordCoreNLP obejmuje TokensRegex [10], platformę do definiowania wyrażeń regularnych. Stosuje się ją do identyfikowania wzorców w tekście i tworzenia reguł na podstawie dopasowanego tekstu. Regeksów używa się do dopasowywania deterministycznego — tzn. coś albo pasuje, albo nie. Regeksy probabilistyczne to odmiana wyrażeń regularnych, która nie ma tego ograniczenia i pozwala określać prawdopodobieństwo dopasowania. Zainteresowani czytelnicy mogą przyjrzeć się bibliotekom takim jak pregex [11].

Gramatyka bezkontekstowa (ang. *context-free grammar* — CFG) to typ formalnej gramatyki używanej do modelowania języków naturalnych. Jej twórcą jest profesor Noam Chomsky, słynny lingwista i naukowiec. CFG można wykorzystać do wyodrębniania bardziej skomplikowanych, hierarchicznych informacji, które mogłyby umknąć wyrażeniu regularnemu. Parser Earley [12] umożliwia analizę składniową tekstu według najróżniejszych gramatyk CFG. Aby modelować bardziej skomplikowane reguły, można posłużyć się językiem gramatycznym takim jak JAPE (Java Annotation Patterns Engine) [13]. JAPE łączy funkcje regeksów i gramatyk CFG i jest używany w opartych na regułach systemach NLP takich jak GATE (General Architecture for Text Engineering) [14]. GATE przydaje się do ekstrakcji tekstu w zamkniętych, dobrze zdefiniowanych dziedzinach, w których ważne są dokładność i kompletność. Na przykład JAPE i GATE wykorzystano do ekstrakcji informacji o procedurach wszczepiania implantów z raportów klinicznych [15]. Na rysunku 1.10 jako przykład systemu opartego na regułach pokazano interfejs GATE z kilkoma wyróżnionymi w tekście typami informacji.

Reguły i heurystyka wciąż odgrywają ważną rolę w cyklu życia projektów NLP. Są dobrym sposobem na budowanie początkowych wersji systemów NLP. Mówiąc najprościej: reguły i heurystyka pomagają szybko zbudować pierwszą wersję modelu i lepiej zrozumieć problem. Omówimy to szczegółowo w rozdziałach 4. i 11. Reguły i heurystyka bywają też przydatne jako dodatkowe funkcje systemów NLP opartych na uczeniu maszynowym. Używa się ich m.in. do domykania luk w systemie. Każdy system NLP zbudowany z wykorzystaniem technik statystycznych, uczenia maszynowego lub uczenia głębokiego będzie popełniał pomyłki. Niektóre pomyłki mogą być zbyt kosztowne — jak w przypadku systemu medycznego, który analizuje dokumentację pacjenta i błędnie decyduje, że nie trzeba wykonywać jakiegoś krytycznego testu. Tego rodzaju pomyłka mogłaby nawet kosztować czyjeś życie. Reguły i heurystyka to świetny sposób na wyeliminowanie takich luk z systemu produkcyjnego. Przejdźmy teraz do technik uczenia maszynowego stosowanych w NLP.

Uczenie maszynowe w NLP

Techniki uczenia maszynowego stosuje się do danych tekstowych tak samo jak do innych form danych, takich jak obrazy, mowa i dane ustrukturyzowane. Metody uczenia nadzorowanego, np. klasyfikację i regresję, intensywnie wykorzystuje się do różnych zadań NLP. Przykładowym zadaniem klasyfikacyjnym NLP jest klasyfikowanie artykułów prasowych według określonych tematów, takich

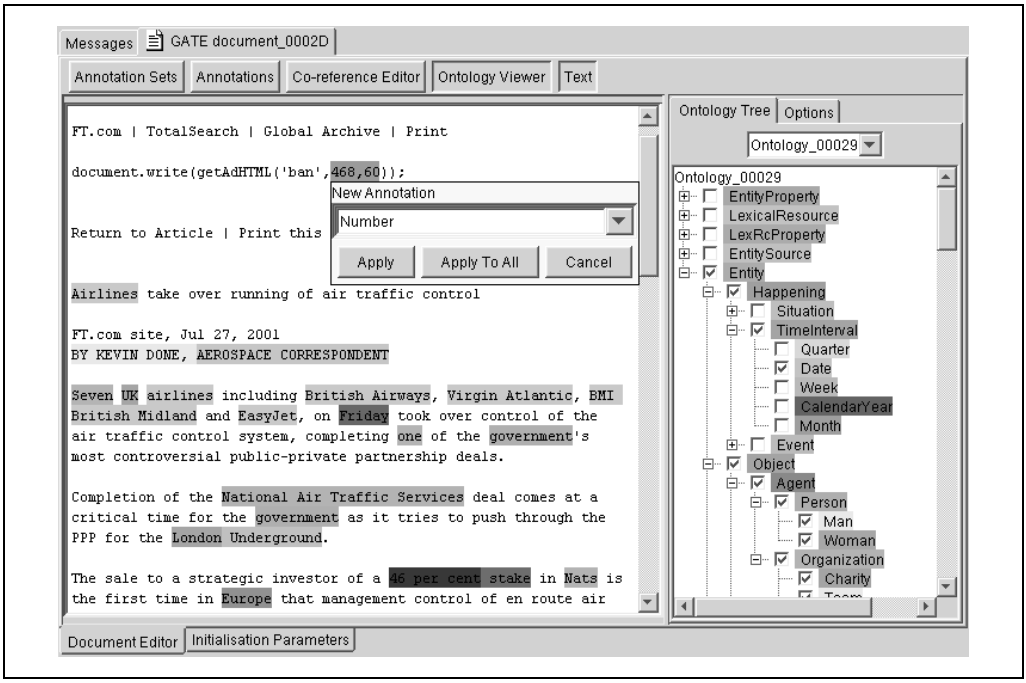

Rysunek 1.10. Narzędzie GATE

jak sport lub polityka. Natomiast metody regresyjne, które dają prognozę liczbową, można wykorzystać do szacowania ceny akcji na podstawie dyskusji o tych akcjach w mediach społecznościowych. Ponadto nienadzorowanych algorytmów grupowania można użyć do sortowania dokumentów tekstowych.

Każde podejście do NLP oparte na uczeniu maszynowym, nadzorowanym czy nie, zwykle składa się z trzech etapów: ekstrakcja cech z tekstu, użycie reprezentacji cech do uczenia modelu oraz ocenianie i ulepszanie modelu. Więcej o reprezentacji cech w odniesieniu do tekstu powiemy w rozdziale 3., a o ocenianiu — w rozdziale 2. Teraz krótko omówimy niektóre metody nadzorowanego uczenia maszynowego modeli NLP, których często używa się na drugim etapie (zastosowanie reprezentacji cech do uczenia modelu). Podstawowa wiedza o tych metodach pomoże Ci zrozumieć pojęcia omawiane w dalszych rozdziałach.

Naiwny klasyfikator bayesowski

Naiwny klasyfikator bayesowski to klasyczny algorytm do zadań klasyfikacyjnych [16], który opiera się głównie na twierdzeniu Bayesa (jak widać po nazwie). Wykorzystując twierdzenie Bayesa, oblicza prawdopodobieństwo zaobserwowania pewnej etykiety klasy na podstawie zbioru cech danych wejściowych. Charakterystyczne dla tego algorytmu jest to, że zakłada, iż każda cecha jest niezależna od innych. We wspomnianym wcześniej przykładzie klasyfikowania artykułów prasowych jednym ze sposobów liczbowego reprezentowania tekstu byłoby użycie liczb słów specyficznych dla poszczególnych dziedzin, takich jak sport lub polityka, które są obecne w tekście. Zakładamy, że liczby te nie są skorelowane. Jeśli to założenie jest uzasadnione, możemy użyć naiwnego

klasyfikatora bayesowskiego do klasyfikowania artykułów prasowych. Choć w wielu przypadkach założenie to jest wątpliwe, naiwny klasyfikator bayesowski powszechnie stosuje się jako początkowy algorytm do klasyfikowania tekstów, głównie dlatego, że jest zrozumiały oraz bardzo szybki w treningu i użyciu.

Maszyna wektorów nośnych

Innym popularnym algorytmem klasyfikacyjnym jest maszyna wektorów nośnych (ang. *support vector machine* — SVM) [17]. Celem każdej metody klasyfikacji jest wyznaczenie granicy decyzyjnej, która rozdziela różne kategorie tekstu (np. polityka kontra sport w naszym przykładzie klasyfikacji artykułów). Ta granica decyzyjna może być liniowa albo nieliniowa (np. okrąg). Maszyna SVM może nauczyć się zarówno liniowej, jak i nieliniowej granicy decyzyjnej w celu oddzielania punktów danych należących do różnych klas. W przypadku liniowej granicy decyzyjnej dane są reprezentowane w sposób, w którym różnice między klasami stają się oczywiste. Jeśli chodzi o dwuwymiarowe reprezentacje cech, przykład pokazano na rysunku 1.11, na którym czarne i białe punkty należą do różnych klas (np. do artykułów sportowych i politycznych). SVM uczy się optymalnej granicy decyzyjnej, maksymalizując odległość między punktami należącymi do różnych klas. Największą zaletą maszyn SVM jest odporność na zmienność i szumy w danych. Głównymi wadami są czas treningu i złe skalowanie w przypadku dużej ilości danych treningowych.

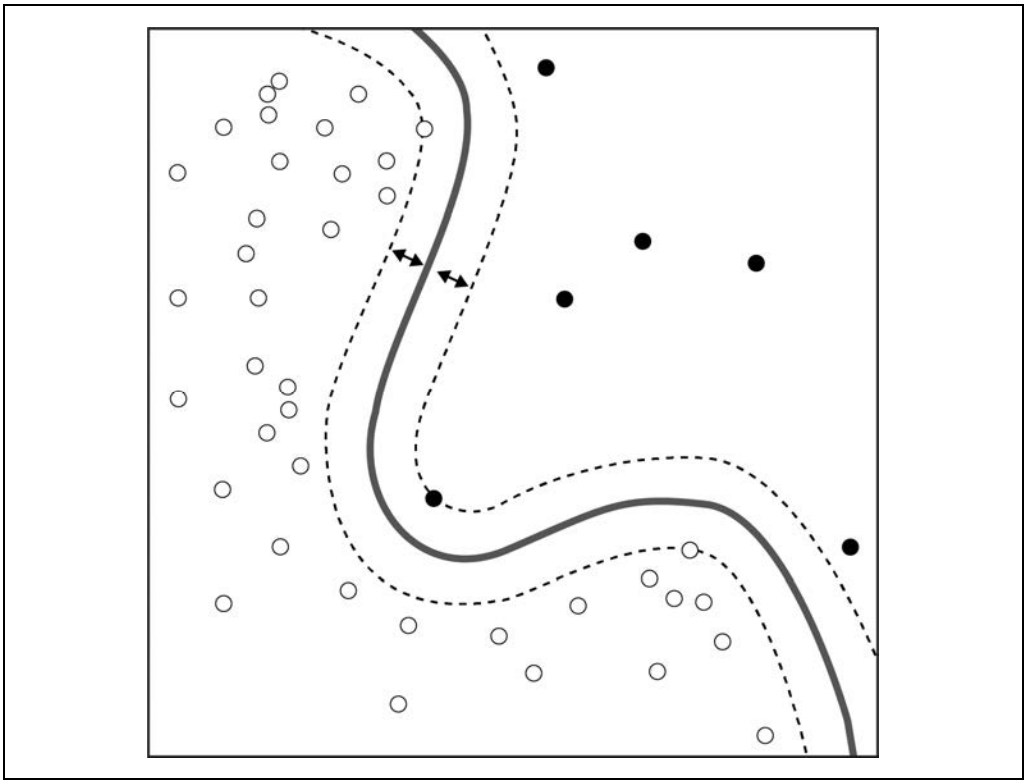

Rysunek 1.11. Dwuwymiarowa reprezentacja cech SVM

Ukryty model Markowa

Ukryty model Markowa (ang. *Hidden Markov Model* — HMM) to model statystyczny [18], który zakłada, że istnieje nieobserwowalny proces z ukrytymi stanami, który generuje dane — tzn. możemy zaobserwować dane dopiero po tym, jak zostaną wygenerowane. HMM próbuje następnie wymodelować ukryte stany na podstawie tych danych. Rozważmy zadanie NLP polegające na oznaczaniu części mowy (ang. *part of speech* — POS), które przypisuje tagi POS wyrazom w zdaniu. Zakładamy tu, że tekst jest generowany według pewnej bazowej gramatyki, która jest ukryta pod tekstem. Ukryte stany to części mowy, które definiują strukturę zdania zgodnie z gramatyką języka, ale my obserwujemy tylko słowa, które podlegają tym niewidocznym stanom. Jednocześnie modele HMM przyjmują założenie Markowa, co oznacza, że każdy ukryty stan jest zależny od poprzedniego stanu lub stanów. Ludzkie języki mają sekwencyjną naturę, a bieżące słowo w zdaniu zależy od tego, co było wcześniej. Dlatego modele HMM z tymi dwoma założeniami są bardzo skutecznym narzędziem do modelowania danych tekstowych. Na rysunku 1.12 pokazano przykład modelu HMM, który określa części mowy w danym zdaniu. Części mowy takie jak JJ (przymiotnik) i NN (rzeczownik) to stany ukryte, podczas gdy zdanie „natural language processing (nlp) …" jest tym, co obserwujemy bezpośrednio.

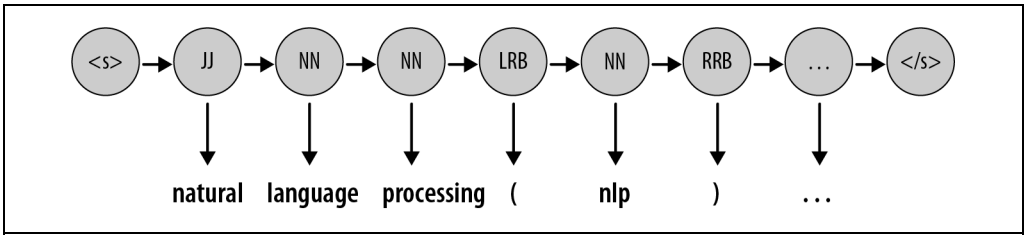

Rysunek 1.12. Reprezentacja graficzna ukrytego modelu Markowa

Szczegółowe omówienie HMM w kontekście NLP znajduje się w rozdziale 8. książki *Speech and Language Processing* profesora Jurafsky'ego [19].

Warunkowe pola losowe

Warunkowe pole losowe (ang. *conditional random field* — CRF) to kolejny algorytm używany do przetwarzania danych sekwencyjnych. CRF zasadniczo przeprowadza zadanie klasyfikacyjne na każdym elemencie w sekwencji [20]. Wyobraź sobie ten sam przykład tagowania POS, w którym CRF potrafi oznaczać słowo po słowie poprzez wybieranie jednej części mowy z puli wszystkich dostępnych tagów POS. Ponieważ algorytm uwzględnia sekwencyjność danych wejściowych i kontekst tagów, jest bardziej ekspresywny niż zwykłe metody klasyfikacji i zazwyczaj działa lepiej. CRF osiąga lepsze wyniki niż HMM w takich zadaniach jak tagowanie POS, które polegają na sekwencyjnej naturze języka. Algorytmy CRF, ich odmiany i zastosowania omówimy w rozdziałach 5., 6. i 9.

Przedstawiliśmy niektóre popularne algorytmy ML, które wykorzystuje się często do zadań NLP. Znajomość tych metod ML pomoże zrozumieć różne rozwiązania omawiane w tej książce. Warto też wiedzieć, kiedy warto używać poszczególnych algorytmów, o czym będzie mowa w kolejnych rozdziałach. Czytelnikom, którzy chcieliby dowiedzieć się więcej o etapach i teoretycznych szczegółach

procesu uczenia maszynowego, polecamy podręcznik *Pattern Recognition and Machine Learning* Christophera Bishopa [21]. Bardziej praktyczne spojrzenie na uczenie maszynowe można znaleźć w doskonałej książce Aureliena Gerona [22]. Przyjrzyjmy się teraz podejściom do NLP opartym na uczeniu głębokim.

Uczenie głębokie w NLP

Krótko wspomnieliśmy o popularnych metodach uczenia maszynowego, których intensywnie używa się w różnych zadaniach NLP. W ciągu kilku ostatnich lat zaczęto na dużą skalę wykorzystywać sieci neuronowe do przetwarzania złożonych, nieustrukturyzowanych danych. Język jest z natury skomplikowany i nieustrukturyzowany, dlatego do zrozumienia i rozwiązania problemów językowych potrzebujemy modeli o większych możliwościach reprezentacji i uczenia się. Oto kilka popularnych architektur głębokich sieci neuronowych, które obecnie są standardem w świecie NLP.

Rekurencyjne sieci neuronowe

Jak wspomniano wcześniej, język jest z natury sekwencyjny. Zdanie w dowolnym języku przepływa w jednym kierunku (np. angielski czyta się od lewej do prawej), zatem model, który potrafi progresywnie odczytywać tekst wejściowy od jednego do drugiego końca, może być bardzo przydatny do zrozumienia języka. Rekurencyjne sieci neuronowe (ang. *recurrent neural network* — RNN) są zaprojektowane specjalnie z myślą o takim sekwencyjnym przetwarzaniu i nauce. Sieci RNN mają jednostki neuronowe zdolne do zapamiętywania, co przetworzyły do tej pory. Pamięć ta jest temporalna, a informacje są zapisywane i aktualizowane w kolejnych etapach czasowych, w miarę jak RNN odczytuje następne słowo z wejścia. Na rysunku 1.13 przedstawiono rozwiniętą sieć RNN i sposób, w jaki śledzi ona dane wejściowe na różnych etapach czasowych.

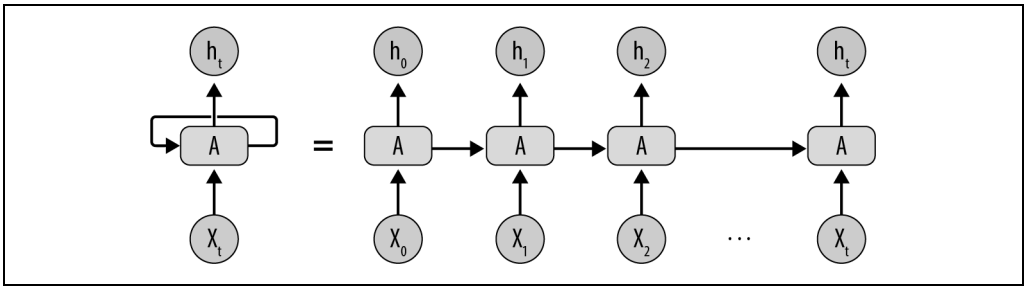

Rysunek 1.13. Rozwinięta rekurencyjna sieć neuronowa [23]

Sieci RNN mają duże możliwości i działają dobrze w różnorodnych zadaniach NLP, takich jak klasyfikacja tekstu, rozpoznawanie nazwanych encji, tłumaczenie maszynowe itd. Sieci RNN można również używać do generowania tekstu, kiedy celem jest odczytywanie poprzedniego tekstu i przewidywanie następnego słowa lub znaku. Szczegółowe omówienie wszechstronności sieci RNN oraz zakresu ich zastosowań w NLP i nie tylko można znaleźć w artykule *The Unreasonable Effectiveness of Recurrent Neural Networks* („Niedorzeczna efektywność rekurencyjnych sieci neuronowych") [24].

Długa pamięć krótkoterminowa

Pomimo swoich możliwości i wszechstronności sieci RNN są „zapominalskie" — nie potrafią zapamiętać dłuższych kontekstów i dlatego nie działają dobrze, gdy wprowadzany tekst jest długi, co zwykle ma miejsce w przypadku danych tekstowych. Sieci z długą pamięcią krótkotrwałą (ang. *long short-term memory* — LSTM), odmianę sieci RNN, wymyślono w celu złagodzenia tego problemu. Sieci LSTM omijają go, ignorując nieistotny kontekst i zapamiętując tylko tę część kontekstu, która jest potrzebna do rozwiązania danego zadania. Eliminuje to konieczność zapamiętywania bardzo długiego kontekstu w jednej reprezentacji wektorowej. Z tej przyczyny sieci LSTM zastąpiły sieci RNN w większości praktycznych zastosowań. Bramkowane jednostki rekurencyjne (ang. *gated recurrent unit* — GRU) to kolejna odmiana RNN, której używa się głównie do generowania języka. (Rodzinę modeli RNN szczegółowo opisuje artykuł Christophera Olaha [23]). Na rysunku 1.14 zilustrowano architekturę pojedynczej komórki LSTM. Konkretne zastosowania LSTM w różnych aplikacjach NLP omówimy w rozdziałach 4., 5., 6. i 9.

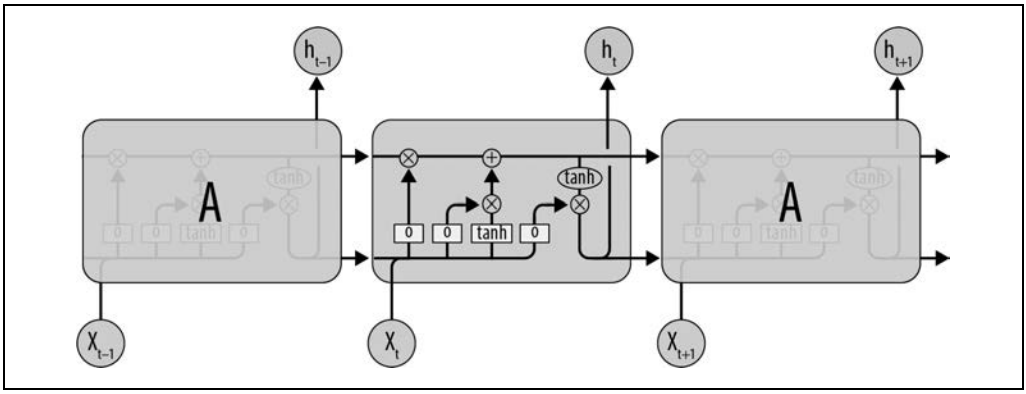

Rysunek 1.14. Architektura komórki LSTM [23]

Konwolucyjne sieci neuronowe

Konwolucyjne sieci neuronowe (ang. *convolutional neural network* — CNN) są bardzo popularne i często używane w zadaniach wizji komputerowej, takich jak klasyfikacja obrazu, rozpoznawanie wideo itd. Odnoszą również sukcesy w NLP, zwłaszcza w zadaniach związanych z klasyfikacją tekstu. Każde słowo w zdaniu można zastąpić odpowiadającym mu wektorem słowa, a wszystkie wektory mają ten sam rozmiar (d) (zob. punkt „Osadzenia słów" w rozdziale 3.). Dzięki temu można układać je jeden na drugim, tworząc macierz lub tablicę 2D o wymiarze $n \times d$, gdzie n to liczba słów w zdaniu, a d to rozmiar wektorów słów. Macierz tę można traktować podobnie jak obraz i modelować za pomocą CNN. Główną zaletą sieci CNN jest możliwość jednoczesnego spojrzenia na grupę słów z wykorzystaniem okna kontekstowego. Na przykład próbujemy klasyfikować odczucia i otrzymujemy wejściowe zdanie typu: „Bardzo lubię ten film!". Aby zrozumieć sens tego zdania, najlepiej przyjrzeć się słowom i różnym zbiorom sąsiadujących ze sobą słów. Sieci CNN potrafią to robić właśnie ze względu na swoją architekturę. Omówimy to dokładniej w późniejszych rozdziałach. Na rysunku 1.15 pokazano sieć CNN, która operuje na fragmencie tekstu w celu wyodrębnienia przydatnych fraz, aby ostatecznie wyznaczyć liczbę binarną wskazującą odczucia wyrażone w zdaniu w danym fragmencie tekstu.

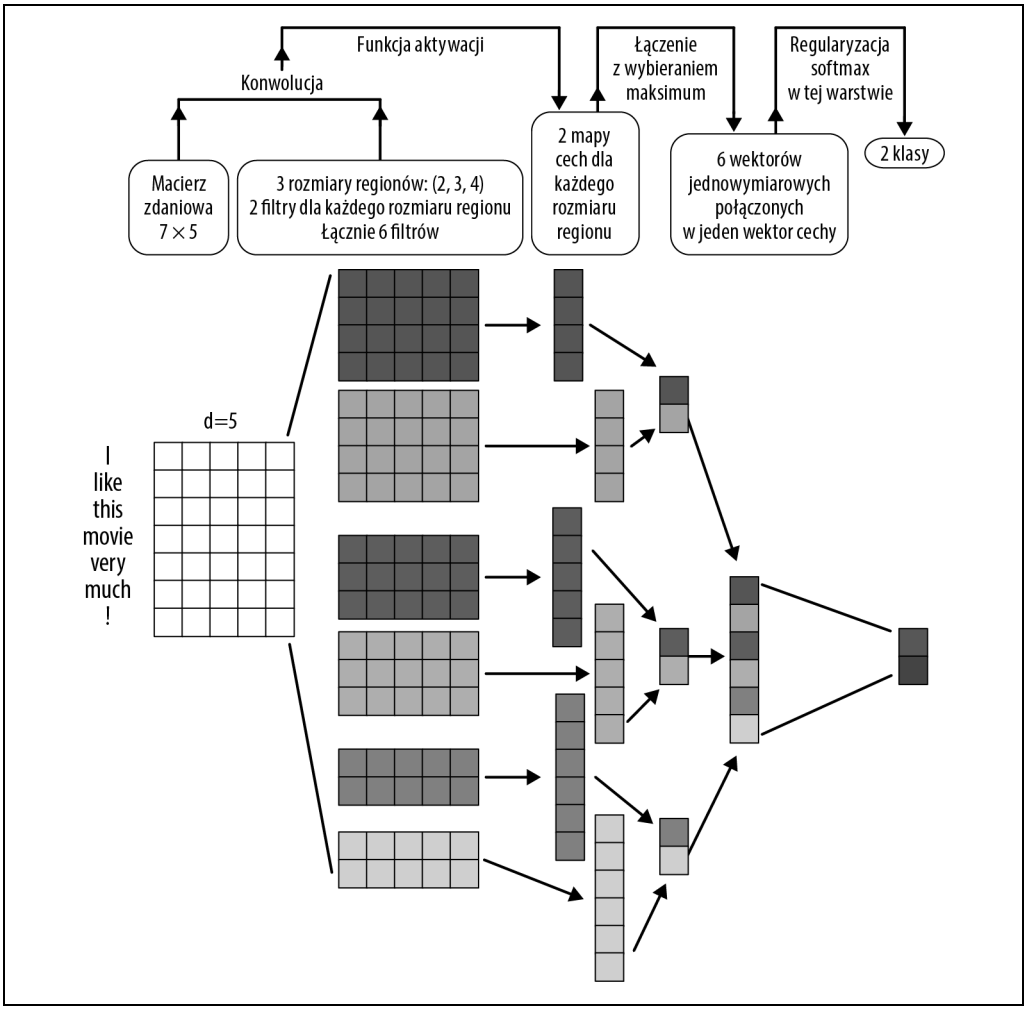

Rysunek 1.15. Model CNN w działaniu [27]

Jak pokazano na rysunku, CNN wykorzystuje zbiór warstw konwolucyjnych i łączących, aby uzyskać skondensowaną reprezentację tekstu, która następnie jest podawana na wejście w pełni połączonej warstwy w celu nauczenia sieci pewnych zadań NLP, takich jak klasyfikacja tekstu. Więcej informacji o używaniu sieci CNN do NLP można znaleźć w pozycjach [25] i [26]. Opiszemy je również w rozdziale 4.

Transformatory

Transformatory [28] to najnowszy konkurent w lidze modeli uczenia głębokiego na użytek NLP. W ciągu ostatnich dwóch lat zastosowano je do prawie wszystkich głównych zadań NLP. Modelują one kontekst tekstowy, ale nie w sposób sekwencyjny. Uwzględniając słowo na wejściu, przyglądają się wszystkim słowom wokół niego (co określa się mianem **samouwagi**) i reprezentują każde

słowo w odniesieniu do jego kontekstu. Na przykład angielskie słowo „bank" może mieć różne znaczenia w zależności od kontekstu, w jakim się pojawia. Kiedy jest mowa o finansach, to „bank" prawdopodobnie oznacza instytucję finansową. Z drugiej strony, jeśli tekst dotyczy rzeki, słowo „bank" prawdopodobnie odnosi się do jej brzegu. Transformatory mogą modelować taki kontekst i dlatego intensywnie używa się ich w zadaniach NLP ze względu na większe zdolności reprezentacji w porównaniu z innymi sieciami głębokimi.

Niedawno duże transformatory zastosowano do **uczenia transferowego** z mniejszymi zadaniami podrzędnymi. Uczenie transferowe to technika AI, w której wiedzy zyskanej podczas rozwiązywania jednego problemu używa się w innym, ale powiązanym problemie. W przypadku transformatorów pomysł polega na tym, żeby wytrenować bardzo duży tryb transformacyjny w sposób nienadzorowany (co nazywa się **treningiem wstępnym**), aby przewidywały część zdania na podstawie reszty treści, a przez to mogły kodować wysokopoziomowe niuanse języka zawartego w tekście. Modele te szkoli się na ponad 40 GB danych tekstowych zgromadzonych z całego internetu. Przykładem dużego transformatora jest BERT (Bidirectional Encoder Representations from Transformers) [29], pokazany na rysunku 1.16, który został wstępnie wytrenowany na ogromnym zbiorze danych i udostępniony na zasadach open source przez Google'a.

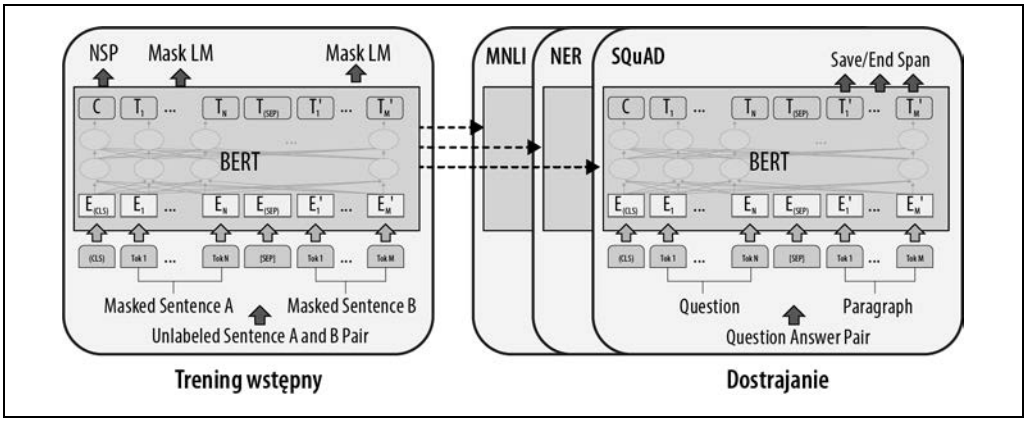

Rysunek 1.16. Architektura BERT — wstępnie wytrenowany model i dostrojone modele specyficzne dla zadania

Wstępnie wytrenowany model pokazano po lewej stronie rysunku 1.16. Model ten następnie dostraja się do podrzędnych zadań NLP, takich jak klasyfikacja tekstu, ekstrakcja encji, odpowiadanie na pytania itd., jak pokazano po prawej stronie rysunku 1.16. Ze względu na ogromną ilość wstępnie nabytej wiedzy BERT efektywnie przekazuje wiedzę do zadań podrzędnych i w wielu z nich dorównuje najlepszym obecnie znanym technikom. W książce opiszemy wiele przykładów używania BERT-a do różnych zadań. Na rysunku 1.17 przedstawiono działanie mechanizmu samouwagi, który jest kluczowym komponentem transformatora. Zainteresowani czytelnicy mogą zajrzeć do artykułu [30], aby dowiedzieć się więcej o mechanizmach samouwagi i architekturze transformatorów. Model BERT i jego zastosowania omówimy w rozdziałach 4., 6. i 10.

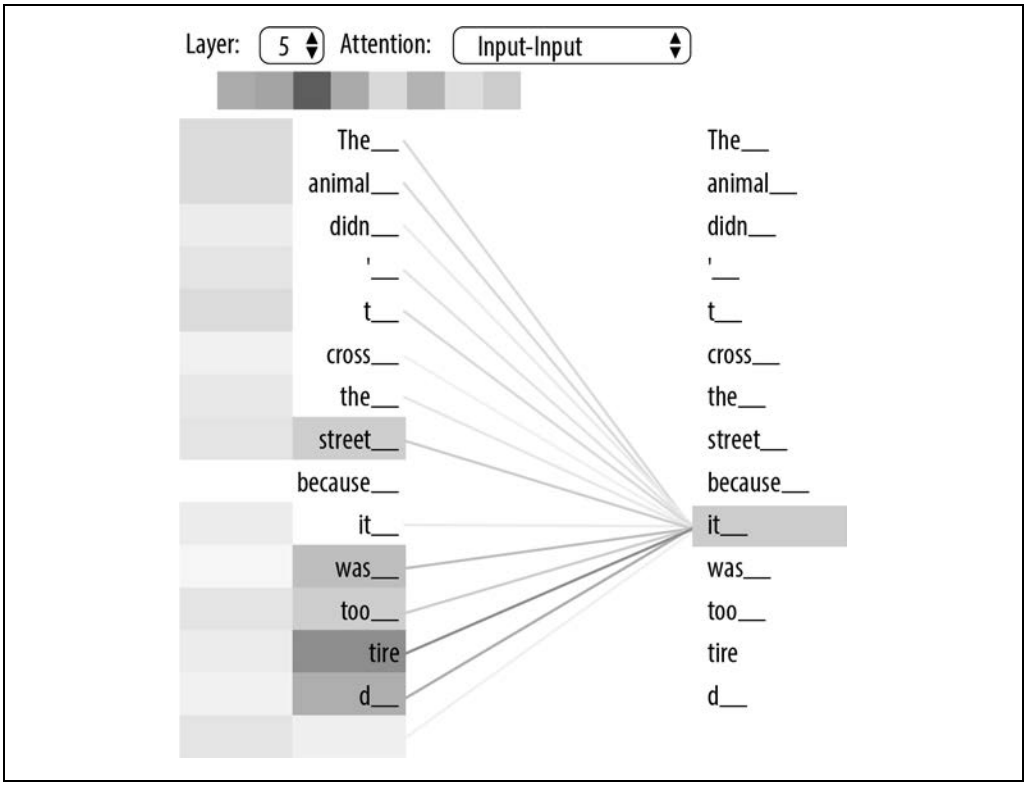

Rysunek 1.17. Mechanizm samouwagi w transformatorze [30]

Autoenkodery

Autoenkoder to sieć innego rodzaju, której używa się głównie do uczenia się skompresowanej reprezentacji wektorowej wejścia. Jeśli chcemy np. reprezentować tekst poprzez wektor, jaki jest na to dobry sposób? Możemy nauczyć się funkcji odwzorowującej tekst wejściowy na wektor. Aby ta funkcja odwzorowująca była użyteczna, „rekonstruujemy" dane wejściowe z powrotem z reprezentacji wektorowej. Jest to forma uczenia nienadzorowanego, ponieważ nie potrzebujemy do niej etykiet dodawanych przez człowieka. Po treningu uzyskujemy reprezentację wektorową, która jest tekstem wejściowym zakodowanym w postaci gęstego wektora. Autoenkoderów zwykle używa się do tworzenia reprezentacji cech potrzebnej do dalszych zadań. Architekturę autoenkodera przedstawiono na rysunku 1.18.

W tym modelu warstwa ukryta zapewnia skompresowaną reprezentację danych wejściowych, która odzwierciedla ich istotę, a warstwa wyjściowa (dekoder) rekonstruuje reprezentację wejściową na podstawie reprezentacji skompresowanej. Choć architektura autoenkodera pokazana na rysunku 1.18 nie radzi sobie ze specyficznymi właściwościami danych sekwencyjnych takich jak tekst, to niektóre odmiany autoenkoderów, np. autoenkoder LSTM, działają całkiem dobrze. Więcej informacji o autoenkoderach można znaleźć w książce [31].

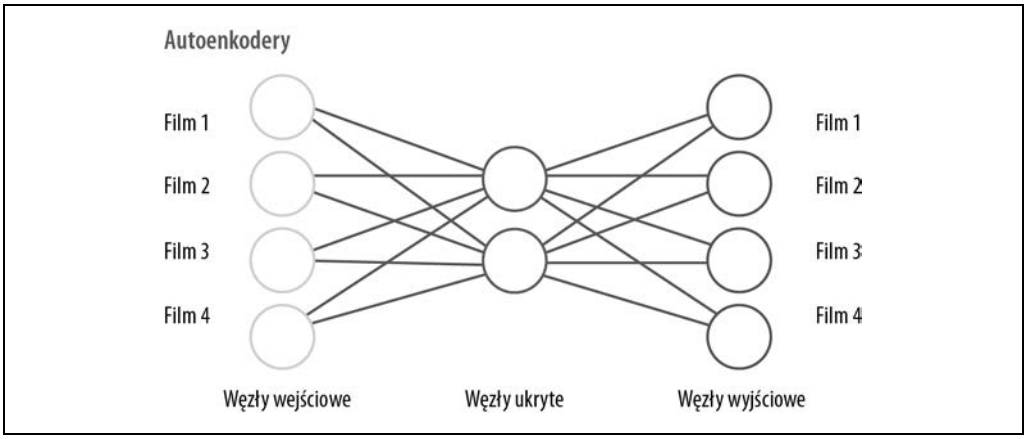

Rysunek 1.18. Architektura autoenkodera

W tym podrozdziale krótko przedstawiliśmy popularne architektury DL związane z NLP. Więcej ogólnych informacji o architekturach uczenia głębokiego znajdziesz w książce [31], a o stosowaniu ich w NLP — w artykule [25]. Mamy nadzieję, że to wprowadzenie pomoże Ci zrozumieć zastosowania DL omawiane dalej w naszej książce.

Zważywszy na niedawne osiągnięcia modeli DL, można by pomyśleć, że DL staje się preferowanym sposobem budowania systemów NLP. W praktyce wygląda to zupełnie inaczej. Wyjaśnijmy, z czego to wynika.

Dlaczego uczenie głębokie nie jest jeszcze „srebrną kulą" NLP?

W ciągu kilku ostatnich lat uczenie głębokie poczyniło wielkie postępy w NLP. Jeśli np. chodzi o klasyfikację tekstu, modele LSTM i CNN przewyższyły skuteczność standardowych technik uczenia maszynowego, takich jak naiwny klasyfikator bayesowski i SVM, w wielu zadaniach klasyfikacyjnych. Modele LSTM działają też lepiej w zadaniach etykietowania sekwencji, takich jak ekstrakcja encji, w porównaniu z modelami CRF. Niedawno faktycznym standardem w większości tych zadań NLP, od klasyfikacji do etykietowania sekwencji, stały się zaawansowane modele transformacyjne. Popularnym trendem jest używanie dużych (pod względem liczby parametrów) transformatorów, trenowanie ich na ogromnych zbiorach danych pod kątem ogólnych zadań NLP, takich jak modelowanie językowe, a następnie dostosowywanie ich do mniejszych zadań. To podejście (znane jako **uczenie transferowe**) przyniosło również sukcesy w innych dziedzinach, takich jak wizja i mowa komputerowa.

Pomimo tych sukcesów DL wciąż nie jest panaceum na wszystkie problemy NLP w rzeczywistych zastosowaniach. Kilka kluczowych powodów takiego stanu rzeczy opisano poniżej.

Nadmierne dopasowanie w przypadku małych zbiorów danych

Modele DL zwykle mają więcej parametrów niż tradycyjne modele ML, co oznacza, że cechują się większą ekspresywnością. Ma to swoją ciemną stronę. Brzytwa Ockhama [32] sugeruje, że jeśli wszystkie inne kryteria są jednakowe, zawsze powinno się wybierać rozwiązanie prostsze. Często zdarza się, że w fazie rozwojowej nie jest dostępna wystarczająca ilość danych

treningowych do wyszkolenia skomplikowanej sieci. W takich przypadkach lepiej wybrać prostszy model zamiast DL. Modele DL nadmiernie dopasowują się do małych zbiorów danych, co pogarsza ich zdolność generalizacji, a to z kolei prowadzi do niezadowalającego działania w środowisku produkcyjnym.

Uczenie na nielicznych przykładach i generowanie danych syntetycznych

W takich dziedzinach jak wizja komputerowa uczenie głębokie poczyniło znaczne postępy w uczeniu się na nielicznych przykładach (ang. *few-shot learning*) i w modelach, które potrafią generować obrazy wysokiej jakości [34]. W związku z tym stało się możliwe trenowanie modeli wizji opartych na DL z wykorzystaniem niewielkiej ilości danych, przez co DL znalazło znacznie więcej zastosowań w środowiskach przemysłowych. Nie opracowano jeszcze podobnych technik DL dla NLP.

Adaptacja dziedzinowa

Jeśli weźmiemy duży model DL wytrenowany na zbiorach danych należących do pewnych popularnych dziedzin (np. artykułów prasowych) i zastosujemy go do innej, nowszej domeny (np. postów w mediach społecznościowych), jego działanie może być niezadowalające. Ta ograniczona zdolność do generalizacji wskazuje, że modele DL nie zawsze są użyteczne. Na przykład modele wytrenowane na tekstach internetowych i recenzjach produktów nie będą działały dobrze w takich domenach jak prawo, media społecznościowe czy opieka zdrowotna, w których zarówno syntaktyczna, jak i semantyczna struktura języka jest specyficzna dla domeny. Potrzebujemy wyspecjalizowanych modeli, w których zakodowana jest wiedza dziedzinowa, a mogą to być po prostu specyficzne dla domeny modele oparte na regułach.

Modele interpretowalne

Pominąwszy adaptację dziedzinową, wadą modeli DL jest ograniczona kontrolowalność i interpretowalność, ponieważ w większości przypadków działają one jak czarna skrzynka. Firmy często potrzebują bardziej interpretowalnych wyników, które można wyjaśnić klientowi lub użytkownikowi końcowemu. W takich przypadkach użyteczniejsze mogą być tradycyjne techniki. Na przykład naiwny klasyfikator bayesowski do klasyfikowania odczuć może wyjaśniać wpływ, jaki mają pozytywne i negatywne słowa na przewidywanie wyrażanych odczuć.

Obecnie uzyskanie takich informacji z modelu klasyfikacyjnego opartego na LSTM jest trudne. Kontrastuje to z wizją komputerową, w której modele DL nie są czarnymi skrzynkami. W wizji komputerowej istnieje wiele technik [35], które pozwalają się dowiedzieć, dlaczego model dokonuje konkretnej prognozy. W NLP takie podejścia są rzadziej spotykane.

Zdrowy rozsądek i wiedza o świecie

Choć modele ML i DL uzyskują dobre wyniki we wzorcowych zadaniach NLP, język pozostaje enigmą dla naukowców. Oprócz składni i semantyki język obejmuje wiedzę o otaczającym nas świecie. Język używany do komunikacji polega na logicznym rozumowaniu i zdroworozsądkowym postrzeganiu zdarzeń zachodzących w świecie. Na przykład zdanie „Lubię pizzę" implikuje „Jestem zadowolony, kiedy jem pizzę". Oto przykład bardziej złożonego rozumowania: „Jeśli Jan wyszedł z domu do ogrodu, to Jan nie jest już w domu i obecnie znajduje się w ogrodzie". Dla człowieka to oczywiste, ale komputer potrzebuje wieloetapowego rozumowania, aby zidentyfikować zdarzenia i przewidzieć ich konsekwencje. Ponieważ ta wiedza

o świecie i zdrowy rozsądek są nieodłącznymi częściami języka, ich zrozumienie ma kluczowe znaczenie, jeśli model DL ma radzić sobie z różnymi zadaniami językowymi. Obecne modele osiągają dobre wyniki w standardowych testach, ale wciąż nie są zdolne do zdroworozsądkowego rozumienia i logicznego rozumowania. Prowadzi się prace nad zdroworozsądkową interpretacją zdarzeń i regułami logicznymi (np. rozumowaniem „jeśli — to"), ale nie są one jeszcze dobrze zintegrowane z modelami ML lub DL.

Koszt

Budowanie rozwiązań DL do zadań NLP bywa kosztowne. Wynika to z wielu przyczyn. Modele DL są znane jako pożeracze danych. Gromadzenie i etykietowanie dużego zbioru danych może pochłonąć znaczne środki. Ze względu na rozmiar modeli DL trenowanie ich w celu osiągnięcia pożądanej wydajności może nie tylko wydłużyć cykle rozwojowe, ale także prowadzić do wysokich rachunków za specjalistyczny sprzęt (GPU). Ponadto wdrażanie i utrzymywanie modeli DL bywa drogie zarówno z perspektywy wymagań sprzętowych, jak i nakładów pracy. Wreszcie ponieważ modele te są duże, mogą powodować problemy z opóźnieniami w czasie wnioskowania i być nieprzydatne w sytuacjach, gdy wymagane są małe opóźnienia. Do tej listy można jeszcze dodać dług techniczny wynikający z budowy i utrzymania „ciężkiego" modelu. Mówiąc nieformalnie: dług techniczny to koszt przyszłych przeróbek, który wynika z przedkładania szybkiego ukończenia prac nad dobre wybory projektowe i implementacyjne.

Wdrożenie w urządzeniach

W wielu scenariuszach rozwiązanie NLP musi działać bezpośrednio w urządzeniu końcowym, a nie w chmurze — np. turystyczny system tłumaczenia maszynowego, który wypowiada przetłumaczony tekst nawet bez dostępu do internetu. W takich przypadkach, ze względu na specyfikę urządzenia, rozwiązanie musi działać z ograniczoną pamięcią i zużyciem energii. Większość rozwiązań DL nie radzi sobie z takimi ograniczeniami. Trwają prace nad wdrażaniem DL w urządzeniach końcowych [36, 37, 38], ale nadal jesteśmy daleko od ogólnych rozwiązań.

W większości projektów pojawia się jeden lub wiele wymienionych wyżej czynników. Prowadzi to do dłuższych cykli projektowych i wyższych kosztów (sprzętu, pracy), a skuteczność rozwiązań jest albo porównywalna z modelami ML, albo nawet niższa. Oznacza to niski zwrot z inwestycji i często sprawia, że projekt NLP kończy się niepowodzeniem.

Z powyższej dyskusji wynika, że DL nie zawsze jest preferowanym rozwiązaniem we wszystkich praktycznych aplikacjach NLP. Zaczniemy więc tę książkę od omówienia fundamentalnych aspektów zadań NLP i pokazania, jak je realizować z wykorzystaniem różnych technik, od systemów opartych na regułach do modeli DL. Położymy nacisk na wymagania w zakresie danych i proces budowania modelu, a nie tylko na techniczne szczegóły poszczególnych modeli. Ze względu na szybkie postępy w tej dziedzinie przewidujemy, że w przyszłości pojawią się nowsze, bardziej zaawansowane modele DL, ale podstawowe aspekty zadań NLP nie zmienią się w zasadniczy sposób. Właśnie dlatego najpierw omówimy podstawy NLP i będziemy stopniowo je rozwijać w celu budowania modeli o rosnącej złożoności, zamiast od razu przeskakiwać do najbardziej zaawansowanych technicznie rozwiązań.

Podobnie jak profesor Zachary Lipton z Uniwersytetu Carnegiego i Mellonów i profesor Jacob Steinhardt z Uniwersytetu Kalifornijskiego w Berkeley [39] my również chcemy przestrzec przed czytaniem artykułów naukowych, prac badawczych i blogów na temat ML i NLP bez kontekstu i odpowiedniego przeszkolenia. Bezładna lektura dużej liczby innowacyjnych prac może powodować dezorientację i niezbyt precyzyjne zrozumienie tematu. Wiele najnowszych modeli DL nie jest wystarczająco interpretowalnych, aby wskazać źródła korzyści empirycznych. Lipton i Steinhardt piszą również o mieszaniu terminów technicznych i niewłaściwym użyciu języka w artykułach naukowych poświęconych uczeniu maszynowemu, które często nie wskazują jasno drogi do rozwiązania danego problemu. Dlatego w tej książce dokładnie omawiamy różne koncepcje techniczne dotyczące stosowania ML w zadaniach NLP za pośrednictwem przykładów, kodu i wskazówek w rozdziałach.

Dotychczas omówiliśmy niektóre podstawowe pojęcia związane z językiem, NLP, ML i DL. Zanim podsumujemy rozdział 1., przyjrzyjmy się studium przypadku, by lepiej zrozumieć różne komponenty aplikacji NLP.

Przewodnik po NLP — agenty konwersacyjne

Głosowe agenty konwersacyjne, takie jak Amazon Alexa i Apple Siri, to jedno z najpowszechniejszych zastosowań NLP; są one znane większości ludzi. Typowy model interakcji agenta konwersacyjnego przedstawiono na rysunku 1.19.

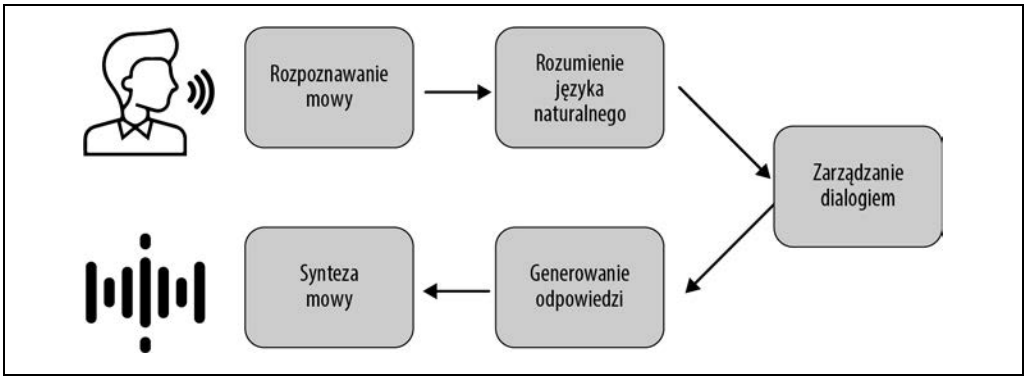

Rysunek 1.19. Przepływ działania agentów konwersacyjnych

Oto najważniejsze komponenty NLP używane w tym przepływie:

1. **Rozpoznawanie i synteza mowy.** Są to podstawowe komponenty każdego głosowego agenta konwersacyjnego. Rozpoznawanie mowy obejmuje przekształcanie sygnałów dźwiękowych na fonemy, które są następnie transkrybowane jako słowa. Synteza mowy to proces odwrotny, polegający na przekształceniu wyników tekstowych w język mówiony. Obie te techniki bardzo się rozwinęły w ostatniej dekadzie, a w większości standardowych przypadków zalecamy realizowanie ich z wykorzystaniem chmurowych interfejsów API.

2. **Rozumienie języka naturalnego.** Jest to kolejny komponent w łańcuchu działań agenta konwersacyjnego, w którym odpowiedź użytkownika (przekształconą w tekst) analizuje się z wykorzystaniem systemu rozumienia języka naturalnego. Można to podzielić na wiele mniejszych podzadań NLP, takich jak:
    - **Analiza odczuć.** Analizujemy tu odczucia wyrażone w odpowiedzi użytkownika. Zostanie to opisane w rozdziale 4.
    - **Rozpoznawanie nazwanych encji.** Tutaj identyfikujemy wszystkie ważne encje wspomniane przez użytkownika w odpowiedzi. Zostanie to opisane w rozdziale 5.
    - **Rozwikływanie odniesień.** Tutaj znajdujemy odniesienia do wyodrębnionych encji w historii konwersacji. Użytkownik może np. powiedzieć: „Avengersi byli fantastyczni", a później odnieść się z powrotem do filmu, mówiąc: „Efekty specjalne w tym filmie były niesamowite". W takim przypadku chcemy połączyć słowo „film" z „Avengersami". Zostanie to krótko opisane w rozdziale 5.
3. **Zarządzanie dialogiem.** Po wyodrębnieniu użytecznych informacji z odpowiedzi użytkownika możemy chcieć zrozumieć jego intencje, np. czy pyta o fakty („Jaka jest dziś pogoda?"), czy wydaje polecenie („Zagraj utwór Mozarta"). Możemy użyć systemu klasyfikacji tekstu, aby klasyfikować odpowiedź użytkownika jako jeden ze wstępnie zdefiniowanych zamiarów. Dzięki temu agent konwersacyjny wie, o co jest proszony. Klasyfikację zamiarów omówimy w rozdziałach 4. i 6. W procesie tym system może zadać kilka dodatkowych pytań wyjaśniających, aby uzyskać dalsze informacje od użytkownika. Kiedy już domyślimy się intencji użytkownika, chcemy ustalić, jakie działania powinien podjąć agent konwersacyjny, aby spełnić żądanie. Robi się to na podstawie informacji i intencji wyodrębnionych z odpowiedzi użytkownika. Właściwym działaniem może być np.: wygenerowanie odpowiedzi na podstawie informacji dostępnych w internecie, odtworzenie muzyki, przyciemnienie świateł lub zadanie pytania wyjaśniającego. Opiszemy to w rozdziale 6.
4. **Generowanie odpowiedzi.** Wreszcie agent konwersacyjny generuje odpowiednie działanie do wykonania na podstawie semantycznej interpretacji intencji użytkownika i dodatkowych informacji uzyskanych w dialogu z użytkownikiem. Jak już wspomniano, agent może pobrać informacje z bazy wiedzy i wygenerować odpowiedź według wstępnie zdefiniowanego szablonu. Może np. powiedzieć: „Odtwarzam XXV symfonię" albo „Światła zostały przyciemnione". W niektórych scenariuszach może nawet wygenerować zupełnie nową odpowiedź.

Mamy nadzieję, że to krótkie studium przypadku pokazało, jak różne komponenty NLP, które będziemy omawiać w tej książce, łączą się w jedną aplikację: agenta konwersacyjnego. W miarę lektury dowiesz się więcej o tych komponentach, a same agenty konwersacyjne zostaną dokładniej opisane w rozdziale 6.

Podsumowanie

W tym rozdziale zbadaliśmy wiele zagadnień związanych z NLP, od szerszych rozważań o tym, czym jest język, do konkretnego studium praktycznej aplikacji NLP. Opisaliśmy też, jak rzeczywiście używa się NLP, jakie są jego główne problemy i zadania i jaką rolę odgrywają w nim uczenie maszynowe i uczenie głębokie. Celem tego rozdziału było przekazanie Ci podstawowej wiedzy,

którą będziesz stopniowo uzupełniał w miarę dalszej lektury. Następne dwa rozdziały (rozdział 2. i 3.) są poświęcone fundamentalnym etapom budowania aplikacji NLP. W rozdziałach od 4. do 7. skupimy się na kluczowych zadaniach NLP i praktycznych problemach, które można rozwiązać za ich pomocą. W rozdziałach od 8. do 10. pokażemy, jak używa się NLP w różnych branżach, takich jak e-commerce, opieka zdrowotna, finanse itd. Rozdział 11. łączy wszystko w całość i wyjaśnia, jak buduje się kompleksową aplikację NLP, w kategoriach projektowania, rozwijania, testowania i wdrażania. Skoro mamy już za sobą to ogólne omówienie, zanurzmy się głębiej w świat NLP.

Bibliografia

[1] Arria.com, *The Power of Language to your industry* (*https://www.arria.com/industry-expertise*), ostatni dostęp: 7 lutego 2023 r.

[2] UCL, Phonetic symbols for English (*https://oreil.ly/5jnsl*), ostatni dostęp: 15 czerwca 2020 r.

[3] Bender Emily M., *Linguistic Fundamentals for Natural Language Processing: 100 Essentials From Morphology and Syntax*, Synthesis Lectures on Human Language Technologies, 6.3 (2013): s. 1 – 184.

[4] Bender Emily M. i Alex Lascarides, *Linguistic Fundamentals for Natural Language Processing II: 100 Essentials from Semantics and Pragmatics*, Synthesis Lectures on Human Language Technologies, 12.3 (2019): s. 1 – 268.

[5] Levesque Hector, Ernest Davis i Leora Morgenstern, *The Winograd Schema Challenge*, The Thirteenth International Conference on the Principles of Knowledge Representation and Reasoning (2012).

[6] Wikipedia, *Dartmouth workshop* (*https://oreil.ly/6NZGh*), ostatnia modyfikacja: 30 marca 2020 r.

[7] Miller George A., *WordNet: A Lexical Database for English*, „Communications of the ACM", 38.11 (1995): s. 39 – 41.

[8] Visual Thesaurus of English Collocations, *Visual Wordnet with D3.js* (*https://oreil.ly/EY1HB*), ostatni dostęp: 15 czerwca 2020 r.

[9] Singh Push, Thomas Lin, Erik T. Mueller, Grace Lim, Travell Perkins i Wan Li Zhu, *Open Mind Common Sense: Knowledge Acquisition from the General Public*, Meersman R. i Tari Z. (red.), *On the Move to Meaningful Internet Systems 2002: CoopIS, DOA, and ODBASE*, OTM 2002, Lecture Notes in Computer Science, vol. 2519, Berlin, Heidelberg: Springer.

[10] The Stanford Natural Language Processing Group, Stanford TokensRegex (*https://oreil.ly/M3KnK*), (oprogramowanie), ostatni dostęp: 15 czerwca 2020 r.

[11] Hewitt Luke, Probabilistic regular expressions (*https://oreil.ly/BqhJX*), (repozytorium na GitHubie).

[12] Earley Jay, *An Efficient Context-Free Parsing Algorithm*, „Communications of the ACM", 13.2 (1970): s. 94 – 102.

[13] *Java Annotation Patterns Engine: Regular Expressions over Annotations* (*https://oreil.ly/dmdOs*), *Developing Language Processing Components with GATE Version 9 (a User Guide)*, rozdział 8., ostatni dostęp: 15 czerwca 2020 r.

[14] General Architecture for Text Engineering (GATE) (*https://gate.ac.uk*), ostatni dostęp: 15 czerwca 2020 r.

[15] Rosier Arnaud, Anita Burgun i Philippe Mabo, *Using Regular Expressions to Extract Information on Pacemaker Implantation Procedures from Clinical Reports*, „AMIA Annual Symposium Proceedings", v. 2008 (2008): s. 81 – 85.

[16] Zhang Haiyi i Di Li, *Naive Bayes Text Classifier*, 2007 IEEE International Conference on Granular Computing (GRC 2007): s. 708.

[17] Joachims Thorsten, *Learning to Classify Text Using Support Vector Machines*, vol. 668, New York: Springer Science & Business Media, 2002, ISBN: 978-1-4615-0907-3.

[18] Baum Leonard E. i Ted Petrie, *Statistical Inference for Probabilistic Functions of Finite State Markov Chains*, „The Annals of Mathematical Statistics", 37.6 (1966): s. 1554 – 1563.

[19] Jurafsky Dan i James H. Martin, *Speech and Language Processing, Third Edition* (wersja robocza) (*https://oreil.ly/sZfWl*), 2018.

[20] Settles Burr, *Biomedical Named Entity Recognition Using Conditional Random Fields and Rich Feature Sets*, Proceedings of the International Joint Workshop on Natural Language Processing in Biomedicine and its Applications (NLPBA/BioNLP), (2004): s. 107 – 110.

[21] Bishop Christopher M., *Pattern Recognition and Machine Learning*, New York: Springer, 2006, ISBN: 978-0-3873-1073-2.

[22] Geron Aurelien, *Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie II*, Helion, 2020, ISBN: 978-83-283-6002-0.

[23] Olah Christopher, *Understanding LSTM Networks* (*https://oreil.ly/X6dwG*), 27 sierpnia 2015 r.

[24] Karpathy Andrej, *The Unreasonable Effectiveness of Recurrent Neural Networks* (*https://oreil.ly/qTAxV*), 21 maja 2015 r.

[25] Goldberg Yoav, *Neural Network Methods for Natural Language Processing*, Synthesis Lectures on Human Language Technologies, 10.1 (2017): s. 1 – 309.

[26] Britz Denny, *Understanding Convolutional Neural Networks for NLP* (*https://oreil.ly/vJppc*), 7 listopada 2015 r.

[27] Le Hoa T., Christophe Cerisara i Alexandre Denis, *Do Convolutional Networks need to be Deep for Text Classification?*, Workshops at the Thirty-Second AAAI Conference on Artificial Intelligence, 2018.

[28] Vaswani Ashish, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser i Illia Polosukhin, *Attention Is All You Need*, *Advances in Neural Information Processing Systems*, 2017: s. 5998 – 6008.

[29] Devlin Jacob, Ming-Wei Chang, Kenton Lee i Kristina Toutanova, *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding* (*https://oreil.ly/xdtmX*), 11 października 2018 r.

[30] Alammar Jay, *The Illustrated Transformer* (*https://oreil.ly/Fl9n3*), 27 czerwca 2018 r.

[31] Goodfellow Ian, Yoshua Bengio i Aaron Courville, *Deep Learning*, Cambridge: MIT Press, 2016, ISBN: 978-0-262-03561-3.

[32] Varma Nakul, *COMS 4771: Introduction to Machine Learning* (*https://oreil.ly/yRJZP*), wykład 6, slajd 7, ostatni dostęp: 15 czerwca 2020 r.

[33] Wang Yaqing, Quanming Yao, James Kwok i Lionel M. Ni, *Generalizing from a Few Examples: A Survey on Few-Shot Learning* (*https://oreil.ly/LyMxm*), (2019).

[34] Wang Zhengwei, Qi She i Tomas E. Ward, *Generative Adversarial Networks in Computer Vision: A Survey and Taxonomy* (*https://oreil.ly/OFvz7*), (2019).

[35] Olah Chris, Arvind Satyanarayan, Ian Johnson, Shan Carter, Ludwig Schubert, Katherine Ye i Alexander Mordvintsev, *The Building Blocks of Interpretability*, Distill 3.3 (marzec 2018): e10.

[36] Nan Kaiming, Sicong Liu, Junzhao Du i Hui Liu, *Deep Model Compression for Mobile Platforms: A Survey*, „Tsinghua Science and Technology", 24.6 (2019): s. 677 – 693.

[37] TensorFlow, *Get started with TensorFlow Lite* (*https://oreil.ly/Jxsuc*), ostatnia modyfikacja: 21 marca 2020 r.

[38] Ganesh Prakhar, Yao Chen, Xin Lou, Mohammad Ali Khan, Yin Yang, Deming Chen, Marianne Winslett, Hassan Sajjad i Preslav Nakov, *Compressing Large-Scale Transformer-Based Models: A Case Study on BERT* (*https://oreil.ly/VSQvc*), (2020).

[39] Lipton Zachary C. i Jacob Steinhardt, *Troubling Trends in Machine Learning Scholarship* (*https://oreil.ly/lpay1*), (2018).

Skorowidz

D

E

F

G

H

I

J

K

L

Ł

M

N

O

P

R

S

Ś

T

U

V

W

Z

Notatki

Ta książka pokazuje anatomię rzeczywistych systemów!

Zachary Lipton, naukowiec i autor książki *Dive Into Deep Learning*

Systemy przetwarzania języka naturalnego charakteryzuje złożoność i unikatowość. Większość podręczników ogranicza się do omówienia problematyki NLP na uproszczonych przykładach i dobrze zdefiniowanych zbiorach danych. Zawarta w nich wiedza jednak nie wystarczy, aby rozwiązać pojawiające się problemy, a następnie zbudować i wdrożyć rzeczywistą aplikację opartą na NLP, z uwzględnieniem specyfiki danej branży i z poszanowaniem najlepszych praktyk.

Książka jest adresowana do wszystkich, którzy chcą budować, rozwijać i skalować systemy NLP w środowisku biznesowym, a także dostosowywać je do swojej branży. Opisuje tworzenie rzeczywistych aplikacji NLP. Omawia pełny cykl życia typowego projektu NLP, od zbierania danych po wdrożenie i monitorowanie modelu. Przedstawia studia przypadków i przewodniki dziedzinowe, pozwalające na zbudowanie systemu NLP od podstaw. Wyczerpująco wyjaśnia, w jaki sposób adaptować rozwiązania do potrzeb różnych branż, takich jak opieka zdrowotna, handel detaliczny i media społecznościowe. Prezentuje szeroką gamę zadań, od klasyfikacji tekstu poprzez odpowiadanie na pytania po ekstrahowanie informacji i systemy dialogowe. Poszczególne zagadnienia są zilustrowane fragmentami kodu, ułatwiającymi zrozumienie logiki omawianych systemów.

W książce między innymi:

- najważniejsze koncepcje związane z NLP
- implementowanie aplikacji NLP z wykorzystaniem uczenia maszynowego
- dostrajanie rozwiązań NLP do konkretnych problemów biznesowych
- skuteczne techniki wydawania, wdrażania i rozwijania systemów NLP
- najlepsze praktyki i strategie NLP dla liderów biznesowych

Sowmya Vajjala pracuje w kanadyjskiej Narodowej Radzie Badań Naukowych. Budowała wielojęzyczne systemy NLP.

Bodhisattwa Majumder jest doktorantem na Uniwersytecie Kalifornijskim w San Diego. Tworzył systemy NLP w Google AI i Microsoft Research.

Anuj Gupta jest dyrektorem w firmie Vahan. Kierował wieloma zespołami zajmującymi się uczeniem maszynowym.

Harshit Surana jest współzałożycielem firmy DeepFlux. Prowadził badania nad NLP i uczeniem maszynowym w MIT Media Lab.

Helion
helion.pl
HELION SA
ul. Kościuszki 1c
44-100 Gliwice
tel.: 32 230 98 63
helion@helion.pl
KOD KORZYŚCI
Sięgnij po więcej!
ISBN 978-83-8322-726-9
9 788383 227269
Cena: 109,00 zł