
Spis treści

Wstęp.....	11
1. Przegląd systemów uczenia maszynowego	19
Kiedy należy używać uczenia maszynowego?	21
Przypadki użycia uczenia maszynowego	26
Zrozumienie systemów uczenia maszynowego	29
Uczenie maszynowe w badaniach i przemyśle	29
Systemy uczenia maszynowego a oprogramowanie tradycyjne	38
Podsumowanie	40
2. Wprowadzenie do projektowania systemów uczenia maszynowego	41
Biznes i cele uczenia maszynowego	42
Wymagania dla systemów uczenia maszynowego	45
Niezawodność	45
Skalowalność	45
Łatwość utrzymania	47
Adaptacyjność	47
Proces iteracyjny	47
Sformalizowanie problemów związanych z uczeniem maszynowym	50
Rodzaje zadań związanych z uczeniem maszynowym	50
Funkcje celu	54
Umysł a dane	57
Podsumowanie	60
3. Podstawy inżynierii danych	61
Źródła danych	62
Formaty danych	64
JSON	65
Formaty wierszowe i kolumnowe	66
Format tekstowy a binarny	68

Modele danych	68
Model relacyjny	69
Model NoSQL	73
Dane ustrukturyzowane a nieustrukturyzowane	76
Silniki przechowywania danych i ich przetwarzanie	77
Przetwarzanie transakcyjne i analityczne	77
Proces ETL — wyodrębnić, przekształć, wczytaj	80
Tryby przepływu danych	82
Dane przekazywane przez bazy danych	82
Dane przekazywane przez usługi	82
Dane przekazywane przez połączenia w czasie rzeczywistym	84
Przetwarzanie wsadowe a przetwarzanie strumieniowe	87
Podsumowanie	88
4. Dane treningowe	90
Próbkowanie	91
Próbkowanie nieprobabilistyczne	91
Proste próbkowanie losowe	93
Próbkowanie warstwowe	93
Próbkowanie wężone	93
Próbkowanie do rezerwuaru	94
Próbkowanie istotnościowe	95
Etykietowanie	96
Etykiety nadawane ręcznie	96
Etykiety naturalne	98
Co zrobić w przypadku braku etykiet?	102
Nie zrównoważenie klas	110
Wyzwania związane z niezrównoważeniem klas	110
Rozwiązywanie problemu niezrównoważenia klas	112
Generowanie sztucznych danych	120
Proste transformacje zachowujące etykiety	120
Perturbacja	121
Synteza danych	123
Podsumowanie	124
5. Inżynieria cech	126
Cechy wyuczone a cechy zaprojektowane	126
Operacje często stosowane w inżynierii cech	129
Obsługa wartości brakujących	129
Skalowanie	132
Dyskretyzacja	133

Kodowanie cech skategoryzowanych	134
Krzyżowanie cech	137
Dyskretne i ciągle osadzenia pozycji	137
Wyciek danych	140
Najczęstsze przyczyny wycieków danych	141
Wykrywanie wycieku danych	144
Tworzenie poprawnych cech	144
Ważność cech	145
Uogólnianie cech	147
Podsumowanie	149
6. Projektowanie modelu i ewaluacja offline	150
Projektowanie i trenowanie modelu	151
Ewaluacja modeli uczenia maszynowego	151
Metody zespołowe	156
Monitorowanie i wersjonowanie eksperymentów	162
Trenowanie rozproszone	167
Zautomatyzowane uczenie maszynowe (AutoML)	171
Ewaluacja modelu w trybie offline	177
Punkty odniesienia	178
Metody ewaluacji	180
Podsumowanie	186
7. Wdrażanie modelu i usługi prognozowania	188
Mity związane z wdrażaniem systemów uczenia maszynowego	190
Mit 1. Jednocześnie wdrażamy tylko jeden lub dwa modele	190
Mit 2. Jeśli nic nie zrobimy, wydajność modelu pozostanie taka sama	192
Mit 3. Modeli nie trzeba często aktualizować	192
Mit 4. Większość inżynierów uczenia maszynowego nie musi się przejmować wielkoskalowymi wdrożeniami	193
Prognozowanie wsadowe a prognozowanie online	193
Od prognozowania wsadowego do prognozowania online	197
Ujednolicenie potoku wsadowego i strumieniowego	199
Kompresowanie modelu	201
Faktoryzacja niższego rzędu	201
Destylacja wiedzy	203
Przycinanie	203
Kwantyzacja	204
Uczenie maszynowe w chmurze i na urządzeniu brzegowym	207
Kompilowanie i optymalizowanie modeli dla urządzeń brzegowych	209
Wykorzystanie uczenia maszynowego w przeglądarkach	216
Podsumowanie	217

8. Zmiana rozkładu danych i monitorowanie	219
Przyczyny awarii w systemach uczenia maszynowego	220
Awarie systemu oprogramowania	221
Awarie specyficzne dla uczenia maszynowego	222
Zmiany rozkładów danych	229
Rodzaje zmian rozkładów danych	230
Ogólne rodzaje zmian rozkładów danych	233
Wykrywanie zmian rozkładów danych	234
Rozwiązywanie problemów związanych ze zmianą rozkładu danych	240
Monitorowanie i obserwowalność	242
Wskaźniki specyficzne dla uczenia maszynowego	243
Narzędzia wspierające proces monitorowania	247
Obserwowalność	251
Podsumowanie	252
9. Uczenie ciągle i testy w środowisku produkcyjnym	254
Uczenie ciągle	255
Ponowne trenowanie bezstanowe i trenowanie stanowe	255
Dlaczego powinno się stosować uczenie ciągle?	259
Wyzwania związane z uczeniem ciągłym	261
Cztery etapy uczenia ciągłego	265
Jak często należy aktualizować modele?	269
Testowanie w środowisku produkcyjnym	271
Użycie kopii rozwiązania	272
Testy A/B	273
Testy kanarkowe	274
Eksperymenty przeplatane	275
Algorytmy bandyty	276
Podsumowanie	280
10. Infrastruktura i narzędzia stosowane w metodyce MLOps	282
Pamięć masowa i moc obliczeniowa	285
Chmura publiczna a prywatne centrum danych	288
Środowisko projektowe	291
Konfiguracja środowiska projektowego	291
Proces standaryzacji środowisk projektowych	294
Przejście ze środowiska projektowego do produkcyjnego — kontenery	296
Zarządzanie zasobami	298
Narzędzie cron, zarządcy procesów i orkiestratory	299
Zarządzanie procesami w danetyce	301

Platforma uczenia maszynowego	306
Wdrażanie modelu	307
Magazyn modeli	308
Magazyn cech	310
Tworzyć czy kupować?	314
Podsumowanie	315
11. Ludzka strona uczenia maszynowego	317
Doświadczenia użytkownika	317
Zapewnianie spójności doświadczeń użytkownika	318
Unikanie prognoz „przeważnie poprawnych”	318
Kompromis szybkość – dokładność	320
Struktura zespołu	320
Współpraca w zespołach międzydyscyplinarnych	321
Wszechstronni danetycy	321
Odpowiedzialna sztuczna inteligencja	325
Nieodpowiedzialna sztuczna inteligencja — studia przypadków	326
Zasady tworzenia odpowiedzialnej sztucznej inteligencji	332
Podsumowanie	337
Epilog	339