4-ДӘРІС

КІРІСПЕ • ТЕОРИЯ • ҚОЛДАНУ

Алгоритмдерді оңтайландыру және бақылаумен/бақылаусыз оқыту

Негізгі ұғымдар, алгоритмдер, робототехника мысалдары және инженерлік проблемалар

Ақ фон • көрнекі схемалар • салыстыру • практикалық тапсырмалар

Дәріс беруші: механика кафедрасының PhD, ассистент-профессоры Б.И. Ахметова

Оқу нәтижелері

- Бақылаумен және бақылаусыз оқытудың мақсаттарын ажырату.
- Loss функциясы, градиент және learning rate ұғымдарын қолдану.
- SGD, Momentum және Adam оптимизаторларының ерекшеліктерін салыстыру.
- Гиперпараметрлерді таңдау және модель сапасын тексеру жолдарын түсіну.
- Робототехникадағы дерек тапшылығы мен drift мәселелерін талдау.

Бақылаумен оқыту (supervised)

Регрессия

Белгіленген мысалдардан сандық мәнді болжайды: мотор температурасы, қашықтық.

Классификация

Сурет не сигналды санатқа бөледі: кедергі / бос жол.

Деректер

Әр кіріс x үшін дұрыс жауап у бар.

Бағалау

MAE, RMSE, precision, recall және F1 қолданылады.

Бақылаусыз оқыту (unsupervised)

Кластеризация

Ұқсас сенсор жазбаларын топтастыру; K-means, DBSCAN.

Өлшемді азайту

PCA белгілер санын ықшамдап, құрылымды көруге көмектеседі.

Аномалия табу

Қалыпты мінез-құлықтан ауытқыған сигналды белгілеу.

Шектеу

Топтарға берілген мағынаны инженер кейін тексеруі тиіс.

Оңтайландыру циклі

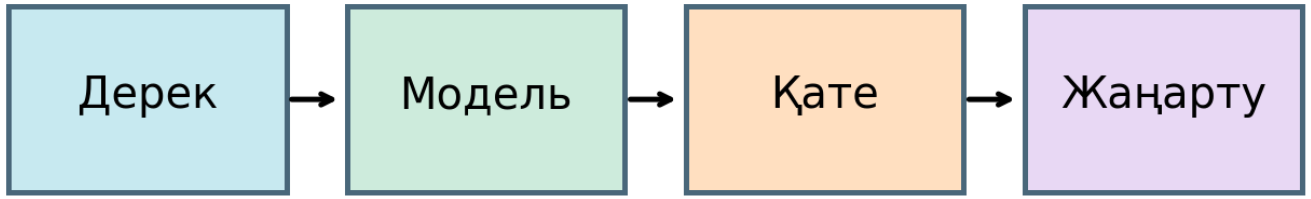

Модель болжау жасайды → қате есептеледі → градиент табылады → параметр жаңарады.

Бұл цикл бірнеше epoch бойы қайталанады; validation сапасы нашарласа, early stopping қолданылады.

Градиенттік түсу

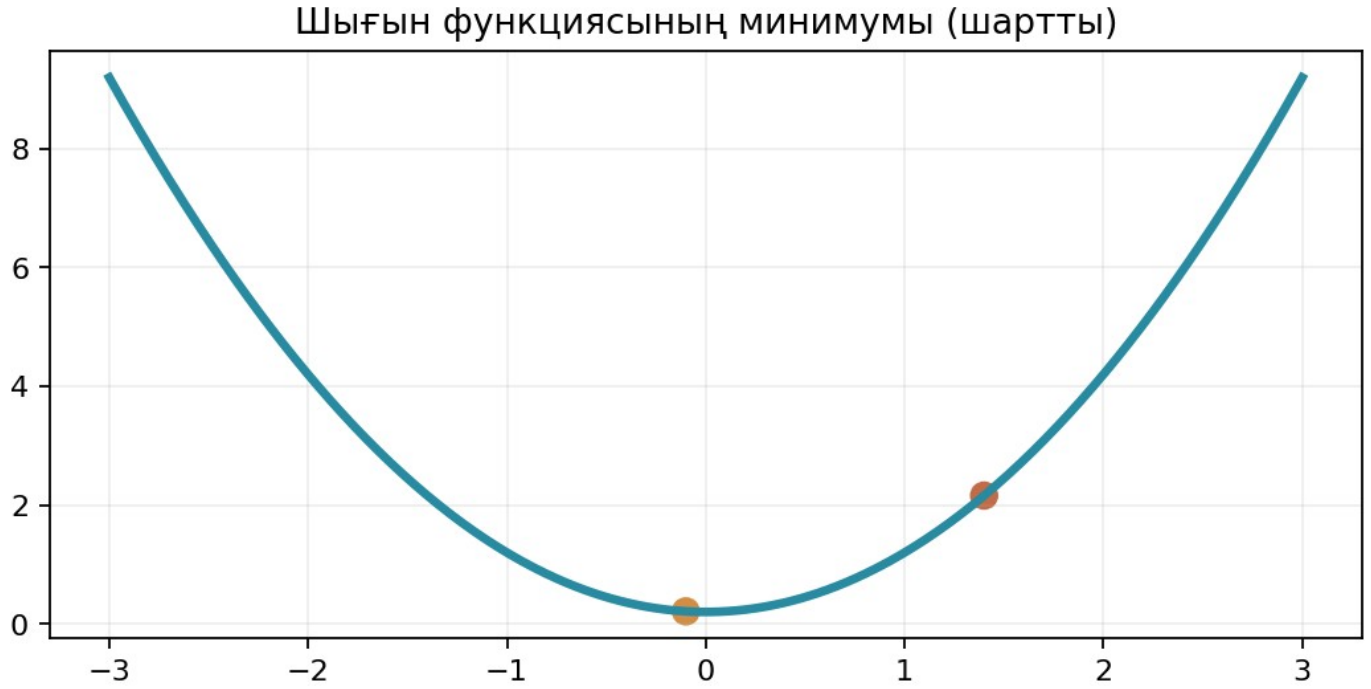

Параметр жаңарту ережесі: $\theta_{t+1} = \theta_t - \eta \nabla L(\theta_t)$.

η тым үлкен болса, шешім тербелуі мүмкін; тым кіші болса, оқыту баяулайды. Сызба — шартты иллюстрация.

SGD, Momentum және Adam

Әдіс	Негізгі идея	Ерекшелік
SGD	Шағын batch градиенті	Қарапайым, шу болуы мүмкін
Momentum	Өткен қадам инерциясы	Тербелісті азайтады
Adam	Бірінші/екінші момент	Жылдам баптауға ыңғайлы
AdamW	Weight decay бөлек	Регуляризацияға қолайлы

Гиперпараметрлер

- Learning rate — параметрді жаңарту қадамы; көбіне ең сезімтал баптау.
- Batch size — бір жаңартуда қолданылатын мысал саны.
- Epoch — оқыту жиынын бір толық өту; тым көп epoch overfitting тудыруы мүмкін.
- Regularization және dropout модель күрделілігін шектейді.
- Cross-validation немесе validation split гиперпараметрлерді салыстыруға көмектеседі.

Екі оқыту тәсілін салыстыру

Критерий	Бақылаумен	Бақылаусыз
Жауап белгісі	Бар	Жоқ
Мақсат	Болжау	Құрылымды ашу
Мысал	Кедергі классификациясы	Ақау сигналдарын топтау
Метрика	F1 / RMSE	Silhouette / сараптамалық тексеру

Проблемалар және шешімдер

Проблема	Нәтиже	Инженерлік шешім
Data leakage	Жалған жоғары сапа	Уақыт/объект бойынша бөлу
Class imbalance	Сирек ақау жоғалады	Class weights, F1
Local minima / plateau	Баяу оқу	Scheduler, Adam
Concept drift	Уақыт өте қате	Мониторинг, қайта оқыту
Қате кластер саны	Топтар сәйкес емес	Silhouette, DBSCAN

Робототехника кейсі

- Өндірістік робот моторының ток және діріл деректері берілген деп есептеңіз.
- Белгіленген ақаулар болса — классификация моделін таңдаңыз.
- Белгісіз ақауларды іздеу үшін кластеризация немесе anomaly detection қолданыңыз.
- Деректерді уақыт бойынша бөліп, leakage болдырмаңыз.
- Қауіпсіздік үшін жалған теріс анықтауды (false negative) азайтуды негіздеңіз.

Қорытынды және сұрақтар

- Оңтайландыру модель параметрлерін, ал гиперпараметр таңдау оқу процесінің тәртібін анықтайды.
- Supervised және unsupervised тәсілдері әртүрлі дерек жағдайында пайдалы.
- Learning rate қандай әсер етеді? Data leakage деген не?
- Неліктен accuracy сирек ақауды анықтауда жеткіліксіз?