Нейрондық желілер және терең оқыту. Архитектуралар, принциптер

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

Мақсат және оқу нәтижелері

- Жасанды нейронның математикалық моделін және оқыту логикасын түсіну.
- MLP, CNN, RNN/LSTM және Transformer архитектураларын салыстыру.
- Forward pass, loss, backpropagation және градиенттік жаңартудың байланысын ашу.
- Робототехникада көру, навигация және ақауды анықтау мысалдарын талдау.
- Деректер тапшылығы, overfitting және есептеу ресурсы мәселелерін бағалау.

Жасанды нейронның моделі

- Кіріс белгілері $x_1…x_n$ салмақтар $w_1…w_n$ арқылы біріктіріледі: $z = \Sigma w_i x_i + b$.
- Белсендіру функциясы нейрон шығысын анықтайды: $a = f(z)$.
- ReLU терең желілерде жиі қолданылады; sigmoid ықтималдыққа ұқсас шығыс үшін пайдалы.
- Нейрондар қабаттарға біріктіріліп, күрделі сызықтық емес тәуелділіктерді үйренеді.

Көпқабатты желі: MLP

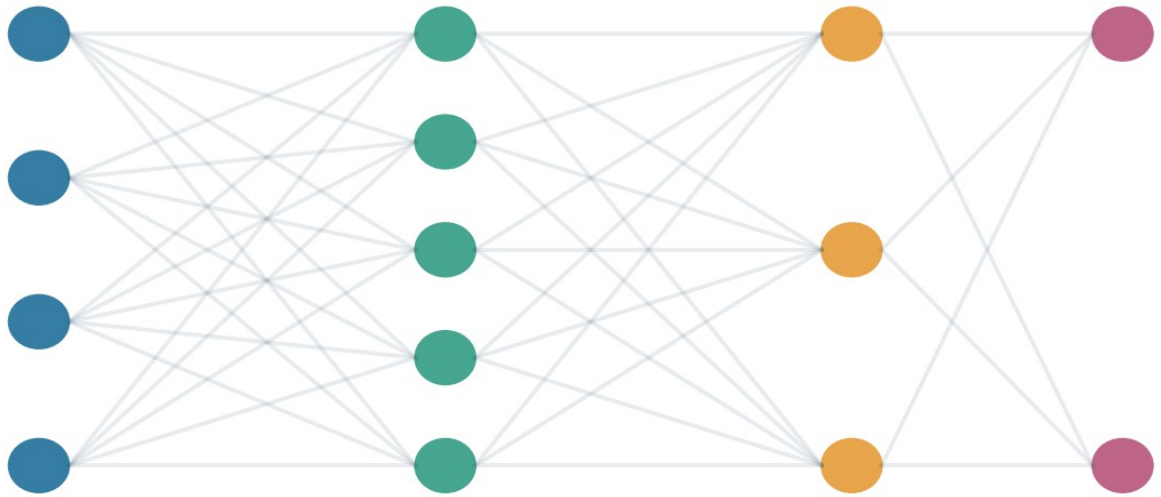

Кіріс қабаты сенсор белгілерін қабылдайды; жасырын қабаттар олардың комбинацияларын өңдейді; шығыс қабаты болжауды береді.

Мысал: мотор тогы, температурасы және дірілі арқылы ақау ықтималдығын бағалау.

Белсендіру функциялары

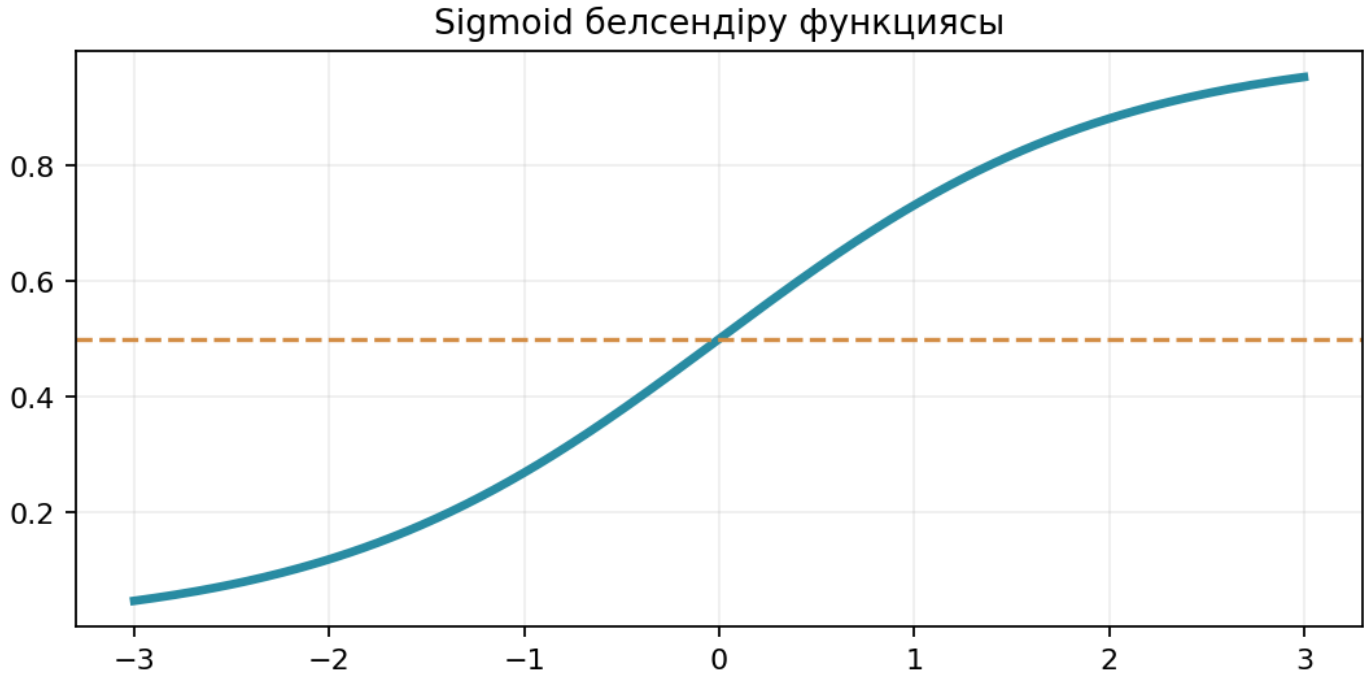

Sigmoid: $f(x)=1/(1+e^{-x})$. ReLU: max(0,x). Softmax бірнеше класқа арналған ықтималдықтарды қалыптастырады.

Белсендіруді дұрыс таңдау градиенттің таралуына және оқыту тұрақтылығына әсер етеді.

CNN, RNN және Transformer

CNN — конволюциялық желі

Кескіннің жергілікті белгілерін бөліп алады; роботтың камерасынан объект тану.

RNN / LSTM

Уақыттық тізбектерді өңдейді; сенсор көрсеткіштері мен қозғалыс тарихын талдау.

Transformer

Attention арқылы ұзақ тәуелділіктерді модельдейді; мультимодальды тапсырмалар.

MLP

Кестелік белгілерді өңдеу; калибрлеу, регрессия және ақау жіктеу.

Желіні оқыту циклі

- Forward propagation: кіріс деректерінен болжау есептеледі.
- Loss функциясы болжау мен шынайы жауап айырмасын өлшейді.
- Backpropagation туындыларды қабаттар бойынша кері таратады.
- Оптимизатор салмақтарды жаңартады: $w \leftarrow w - \eta \nabla L(w)$.
- Validation жиыны арқылы жалпылау қабілеті бақыланады.

Архитектураларды салыстыру

Архитектура	Дерек түрі	Роботтағы міндет
MLP	Кестелік белгілер	Ақау болжамы
CNN	Кескін / видео	Объект анықтау
LSTM	Уақыт қатары	Жетек күйін болжау
Transformer	Тізбек / мультимодаль	Күрделі қабылдау

Робототехникадағы қолданылуы

Компьютерлік көру

Кедергіні, бөлшекті, адамды және ақауды камерадан тану.

Басқаруға көмек

Үйренілген модельмен динамика параметрлерін болжау.

Предиктивті қызмет

Діріл, температура және ток арқылы тозуды ерте анықтау.

Навигация

Семантикалық карта, жүретін аймақты сегментациялау.

Проблемалар және шешімдер

Проблема	Салдары	Шешім
Overfitting	Жаңа ортада қате	Augmentation, regularization
Дерек аз	Нашар жалпылау	Transfer learning
Latency жоғары	Басқару кешігеді	Quantization, edge AI
Domain shift	Симуляция ≠ нақты орта	Domain randomization
Түсіндірілмеу	Қауіпсіздік тәуекелі	Тестілеу, мониторинг

Практикалық тапсырма

- Камерадан бөлшек ақауын анықтайтын CNN жүйесінің кірісі мен шығысын сипаттаңыз.
- Train/validation/test деректерін бөлу жоспарын ұсыныңыз.
- Accuracy-мен қатар precision және recall не үшін керек екенін түсіндіріңіз.
- Роботтағы inference кідірісін және жалған анықтаудың тәуекелін бағалаңыз.

Қорытынды және бақылау сұрақтары

- Терең оқыту күрделі белгілерді автоматты түрде үйренуге мүмкіндік береді.
- Архитектураны таңдау дерек түріне, есептеу қуатына және кідіріс талабына байланысты.
- Backpropagation қалай жұмыс істейді? CNN мен MLP айырмасы қандай?
- Неліктен нақты роботта қауіпсіздік пен жалпылау қабілеті маңызды?