

Masinõpe radioloogias

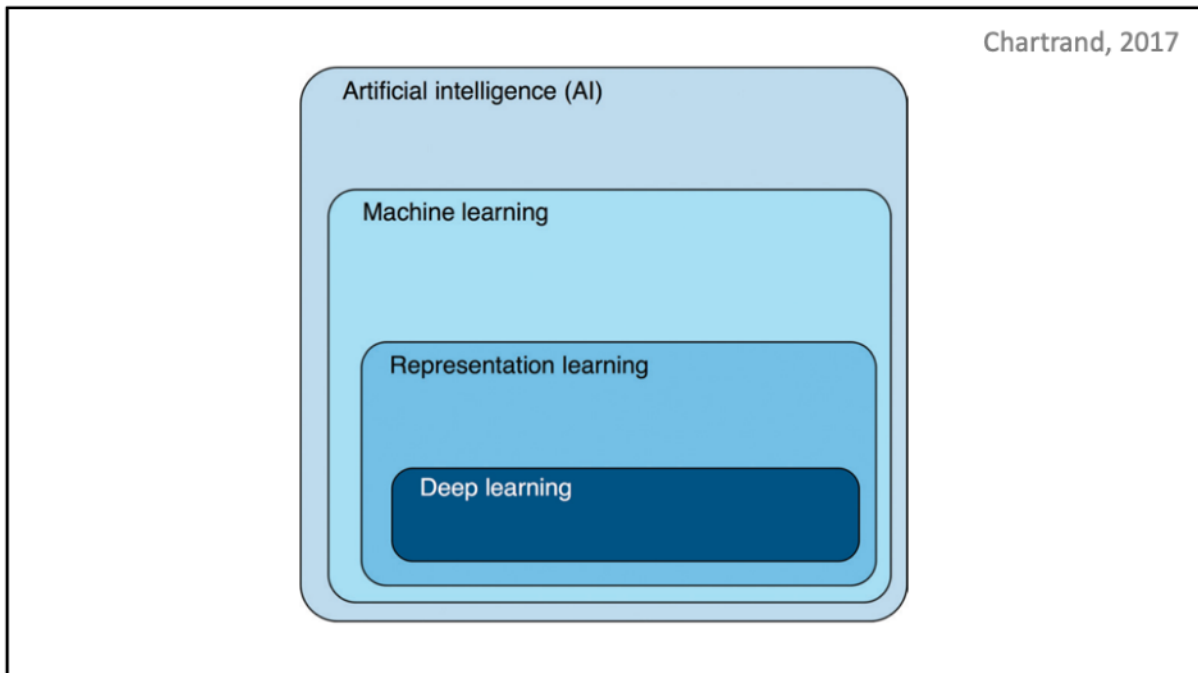
Julius Juurmaa, arst-resident, doktorant



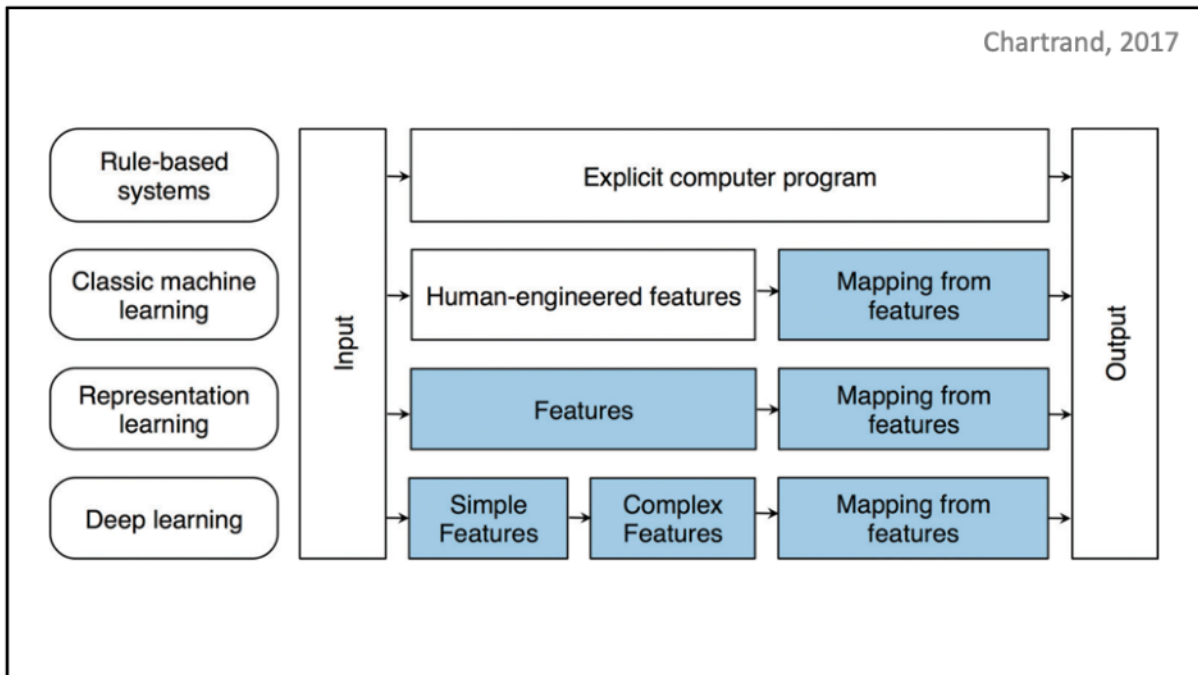
Euroopa Liit
Euroopa
Regionaalarengu Fond




Eesti
tuleviku heaks



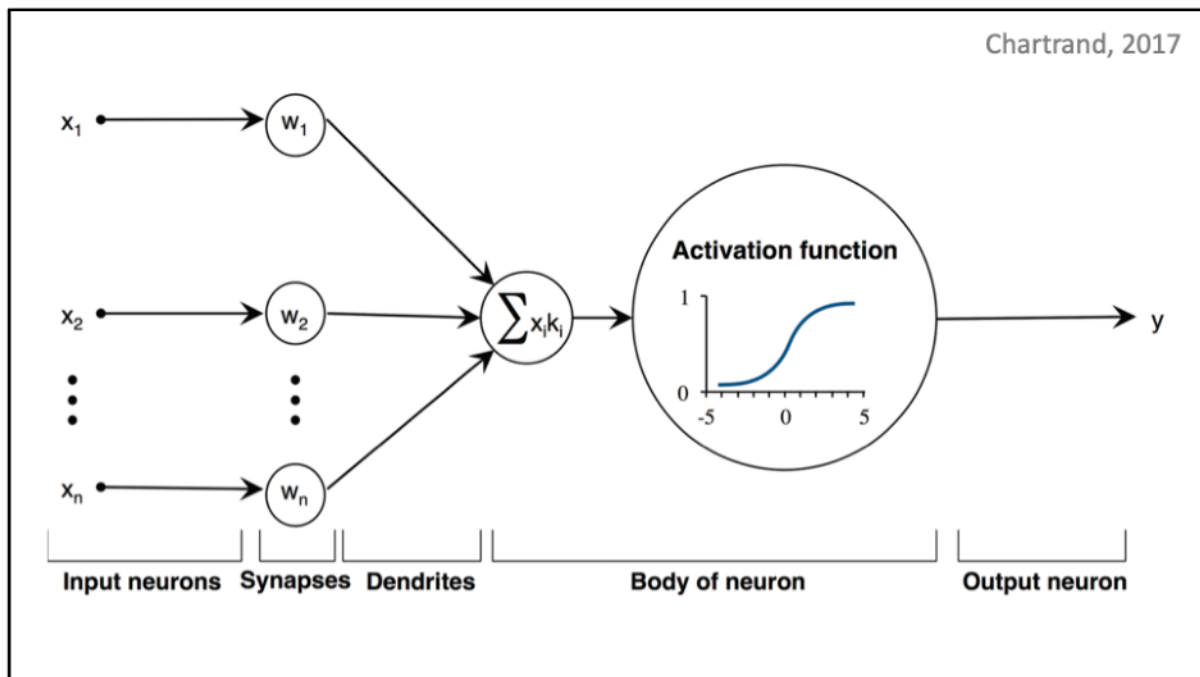
- Tehisintellekt (*artificial intelligence*) on süsteem, mis on võimeline täitma ülesandeid, mis klassikalise arusaama kohaselt on justkui jõukohased üksnes inimhõimustusele
- Masinõppe (*machine learning*) käigus õpetatakse tehisintellekt neid ülesandeid täitma mitte algoritme eksplitsiitselt programmeerides, vaid õpetades süsteemi mustreid ära tundma ja neist järeldusi tegema
- Mustrid (*pattern*) moodustuvad tunnustest (*feature*). Kui tehisintellekt tegeleb KT uuringuga, siis tunnusteks võiks olla nt voksli tihedus natiivis, voksli tihedus parenhümatoosises faasis, või struktuuri kuju (radioloogia klassika—kas struktuur on kera või toru)—tingimus on lihtsalt, et tunnus on arvuliselt esitatav, ja põhimõtteliselt on pea kõike võimalik arvuliselt esitada
- Esitusõppe (*representation learning*) on masinõppe liik, kus tehisintellektile ei pea ka tunnuseid eksplitsiitselt sisse programmeerima, vaid ta suudab need samuti andmetest ise välja lugeda
- Sügavõppe (*deep learning*) on esitusõppe liik, kus tunnustest moodustub loogiline hierarhia, nt voksli tihedus—serv/tekstuur—kujund/kontrasteerumine—lesioon/elund—haigus/seisund




- Valge taustaga komponendid on tehisintellektile eksplitsiitselt ette antud, sinise taustaga komponendid õpib tehisintellekt ise andmete pealt



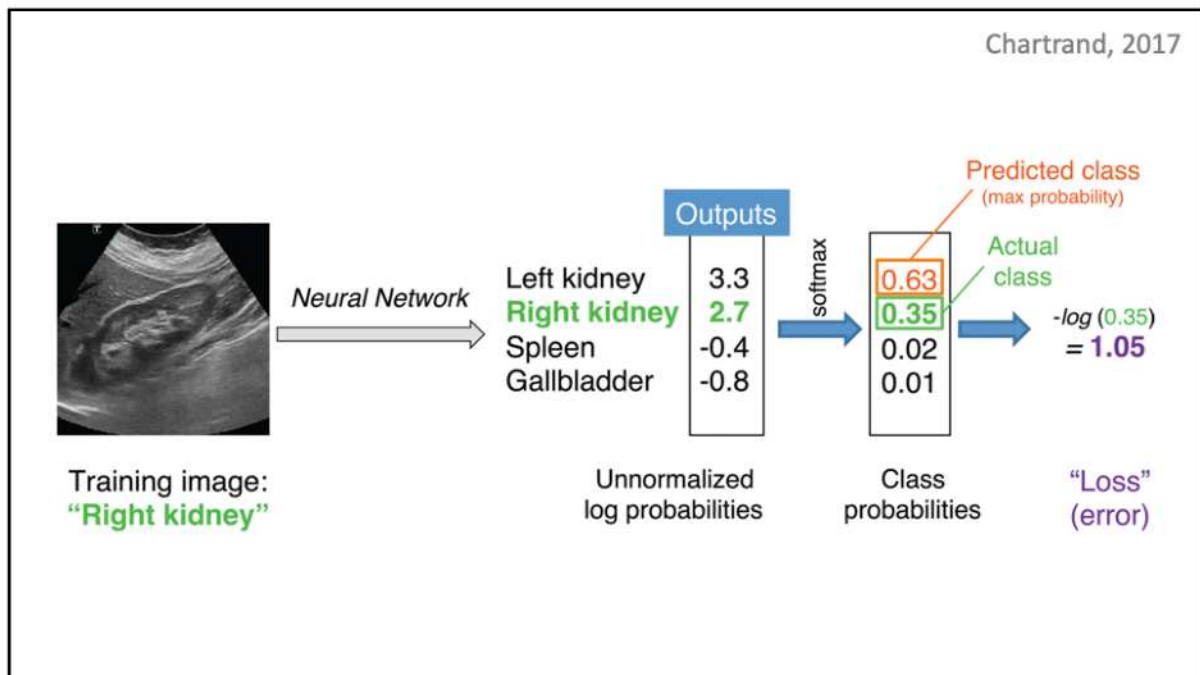
- Sügavõpe leiab aset tehislikus närvivõrgus (*artificial neural network*). Tehislikud närvivõrgud on oma toimimispõhimõtetelt sarnased bioloogiliste närvivõrkudega
- Bioloogiliste närvivõrkude vähim integratiivne ühik on neuron. Neuronil on üks või enam sisendit (dendriiti) ja üks väljund (akson). Dendriitidel paiknevad retseptorid, mis vastava ülekandeainega kohtudes kas de- või hüperpolariseerivad membraani (mängides Na^+ , K^+ , Ca^{2+} ja Cl^- kontsentratsioonide erinevusega teine teisel pool membraani). Membraanipotentsiaali muutus levib elektrotooniliselt aksoni algusse, mida nimetatakse ka aksoni künkaks (*axon hillock*). Kui väikeste muutuste summana tekib piisav depolarisatsioon, avanevad pingesõltuvad Na^+ -kanalid ja käivitub aktsioonipotentsiaal, mis levib elektrotooniliselt või saltatoorselt aksoni otsani, kus vabastatakse ülekandeaine, mis ujub üle sünapsi järgmiste neuronite dendriitideni
- Joonisel: kui nägemisvälja kõrvuti asetsevatele osadele vastavad neuronid annavad aktsioonipotentsiaali, integreeritakse see närvivõrgus servaks ja antakse edasi järgmisele tasemele, mis omakorda integreerivad selle kujundiks, jne
- Õppimine toimub sünaptiliste ühenduste tugevuse moduleerimise kaudu. Hebbi õppimine—koos laenglevate neuronite vaheline ühendus kipub tugevnema (*cells that fire together, wire together*)




- Tehisnärivõrgu vähimat integratiivset ühikut nimetatakse samuti neuroniks
- Matemaatika on väga lihtne. x_1, x_2, \dots, x_n on sisend eelmiselt neuronilt. See sisend korrutatakse läbi neuronite omavahelise ühenduse tugevusega w_1, w_2, \dots, w_n ning tulemused liidetakse kokku. Saadud summa läheb läbi aktivatsioonifunktsiooni (*activation function*). Aktivatsioonifunktsioone on erinevaid—nt sigmoidfunktsioon (*sigmoid function*), mille väärtus jääb alati nulli ja ühe vahele, või mittenegatiivne lineaarfunktsioon (*rectified linear function*), mis on lihtsalt $f(x) = \max(0, x)$. Aktivatsioonifunktsiooni väärtus antaksegi edasi järgmisele neuronile



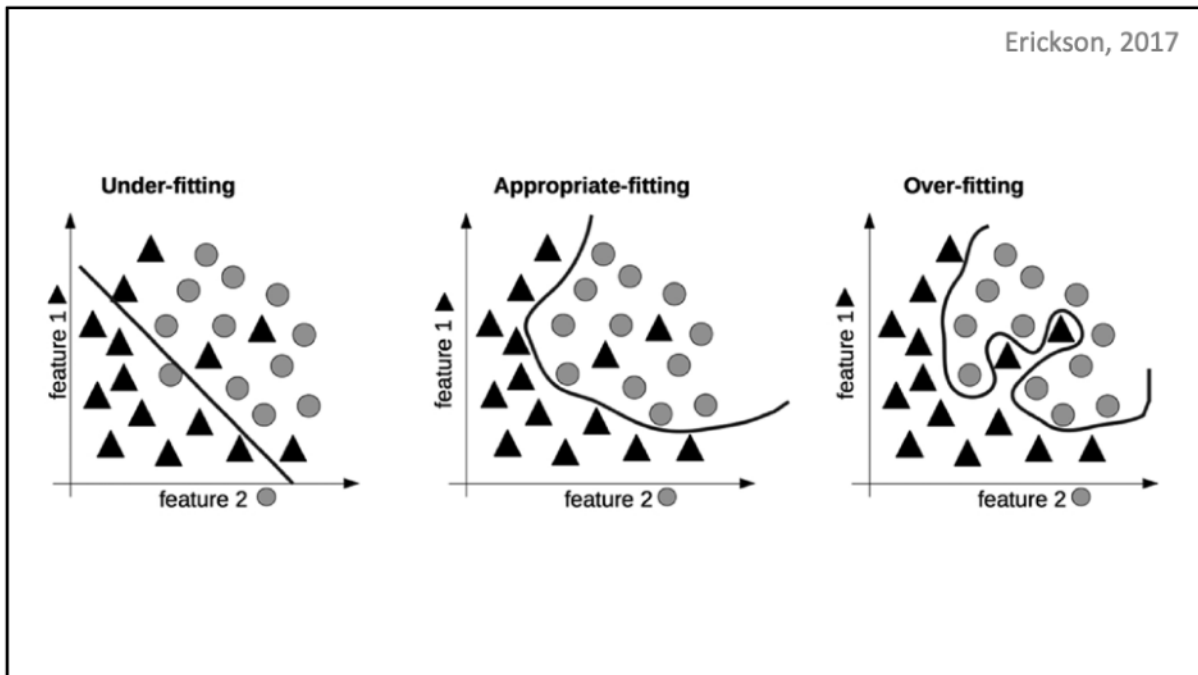
- Sügavõpe on sügav sellepärast, et ta toimub sügavas närvivõrgus
- Sügavas närvivõrgus jäävad sisend- ja väljundkihi vahele mitmed peidetud kihid. Sisendkihi (*input layer*) neuronid vastavad sisendandmete struktuurile, nt peegeldades UH uuringu pikseleid. Väljundkihi (*output layer*) neuronid vastavad sellele tulemusele, mille jaoks närvivõrk loodud on—nt klassifikatsiooni tulemus. Peidetud kihtides (*hidden layer*) toimub samm-sammult liikumine konkreetselt abstraktselt. Mõnedest kihtide tütüpidest tuleb juttu allpool



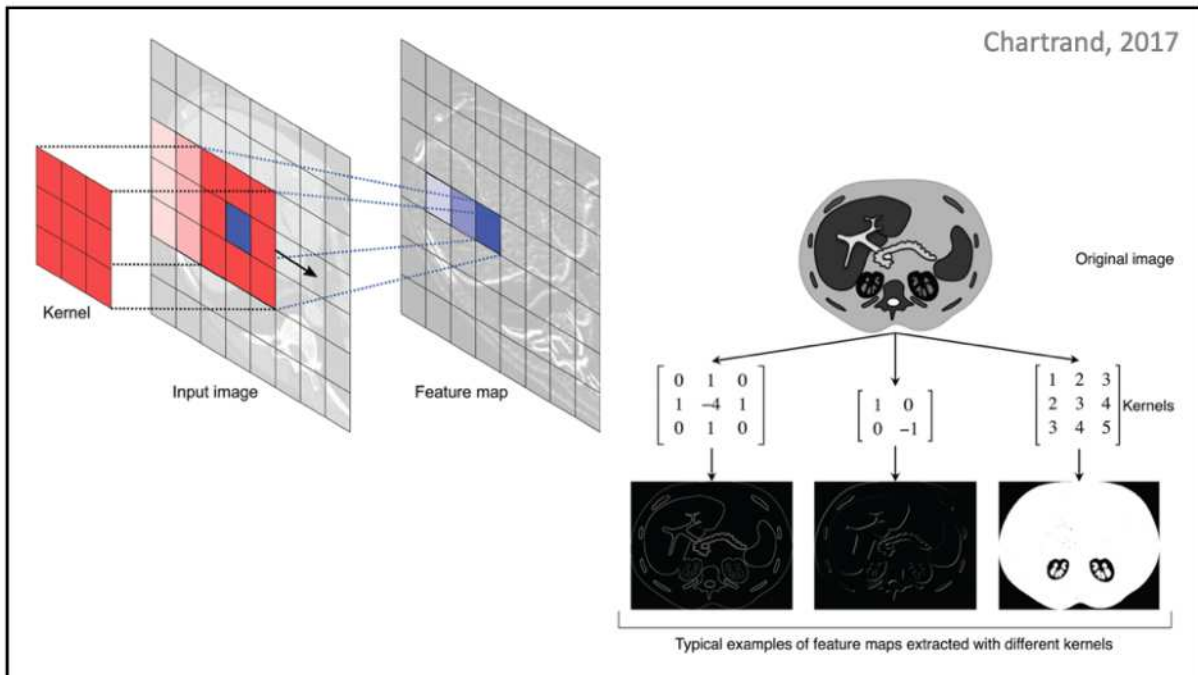
- Kui me saame väljundkihi neuronitelt kätte tulemuse, anname me selle üle funktsioonile, mida me nimetame kaofunktsiooniks (*loss function*). Kaofunktsiooni väärtus peegeldab erinevust saadud tulemuse ja oodatava tulemuse vahel. Meie eesmärk on saada kaofunktsiooni väärtus võimalikult väikeseks
- Joonisel: oletame, et meil on klassifitseeriv närvivõrk. Me anname sisendkihile parema neeru pildi ja saame väljundkihilt vastuseks, et tõenäosus, et tegu on vasaku neeruga, on 0,63 ja tõenäosus, et tegu on parema neeruga, 0,35—mis loomulikult valmistab meile suure pettumuse, sest meie tahaksime, et tõenäosus, et tegu on parema neeruga, ligineks ühele
- Vahemärkus: kui meil on märgendatud (*labeled*) andmed—nagu praegu, kus meil on ports UH pilte, me teame, mis nende peal on ning võrdleme närvivõrgu vastuseid nn õigete vastustega—siis me tegeleme juhendatud õppega (*supervised learning*), mis üldiselt ongi vähemalt meie valdkonnas relevantsem



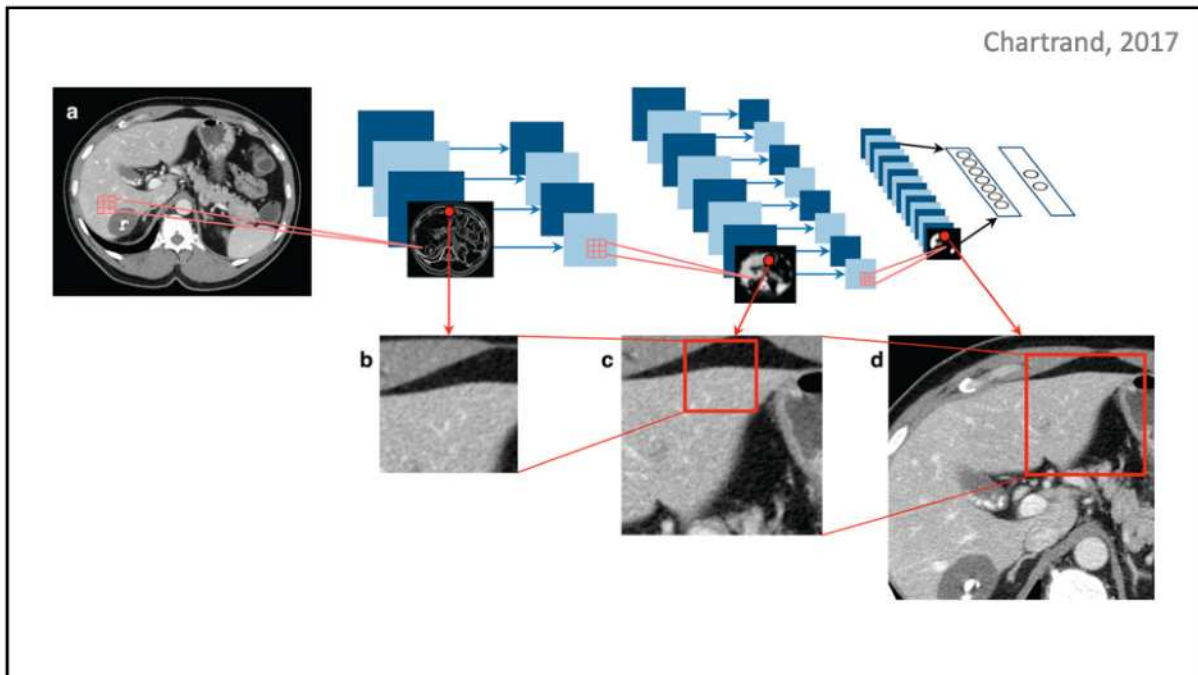
- Järgneb protsess, mida nimetatakse tagasileviks (*backpropagation*). Liigume lihtsalt kiht kihi ja neuron neuronini haaval mööda närvivõrku tagasi—väljundkihist sisendkihi suunas—ning nikerdame neuronite omavaheliste ühenduste tugevuste kallal. Kui me oleme tagasi sisendkihini jõudnud, proovime uute tugevustega uuesti ja vaatame, mis me nüüd kaofunktsiooni väärtuseks saame. See ongi nn õppe osa masinõppes
- Kordame seda tegevust niikaua, kuni kohtame kaofunktsiooni miinimumi—ehk edasiste proovimiste käigus kipub kaofunktsioon üksnes kasvama. Siis oleme loodetavasti oma tehisnärvivõrgu hästi ära treeninud...



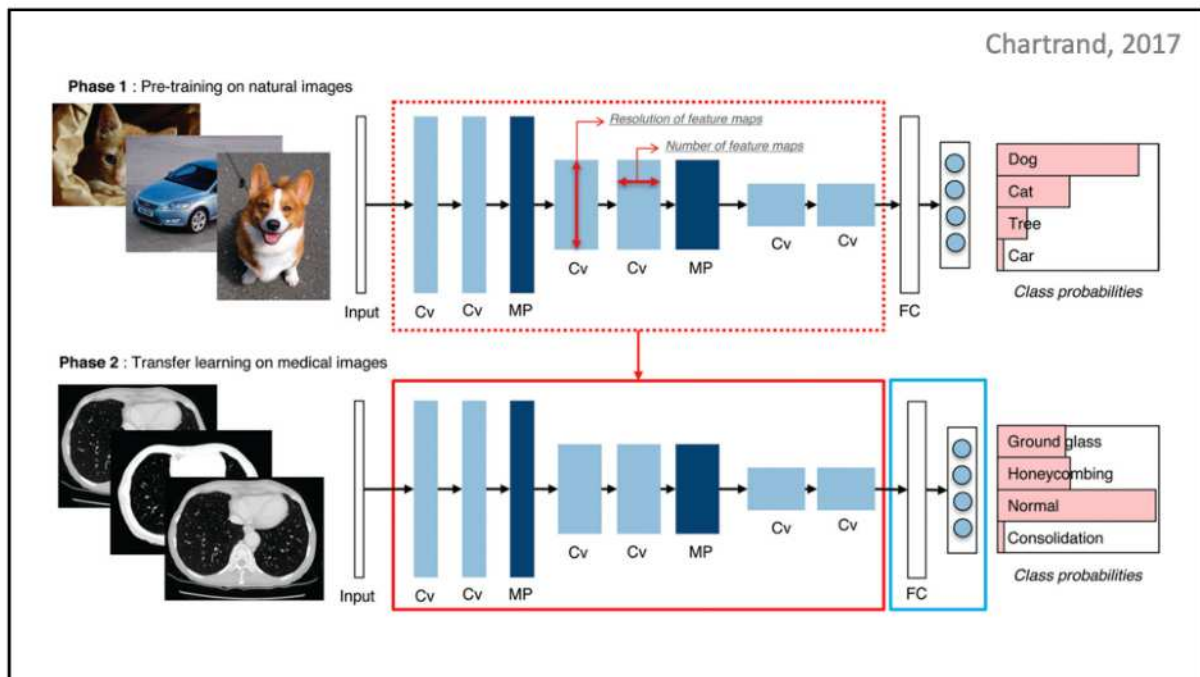
- ...ent nagu me teame: teoorias pole teooria ja praktika vahel vahet, aga praktikas on!
- Meie närvivõrgu treenitus selgub päriselt alles siis, kui me võtame uue andmestiku—valideerimisandmestiku (*validation set*)—ja laseme selle oma närvivõrgust läbi. Võib juhtuda, et oleme tegelenud alasobitusega (*underfitting*)—meie närvivõrk on liiga lihtne, et tegeliku eluga hakkama saada. Või ülesobitusega (*overfitting*)—meie närvivõrk järgib liiga hästi treeningandmestiku (*training set*) sisemist struktuuri ja ei saa sellepärast tegeliku eluga hakkama. Mingi viga jääb muidugi alati



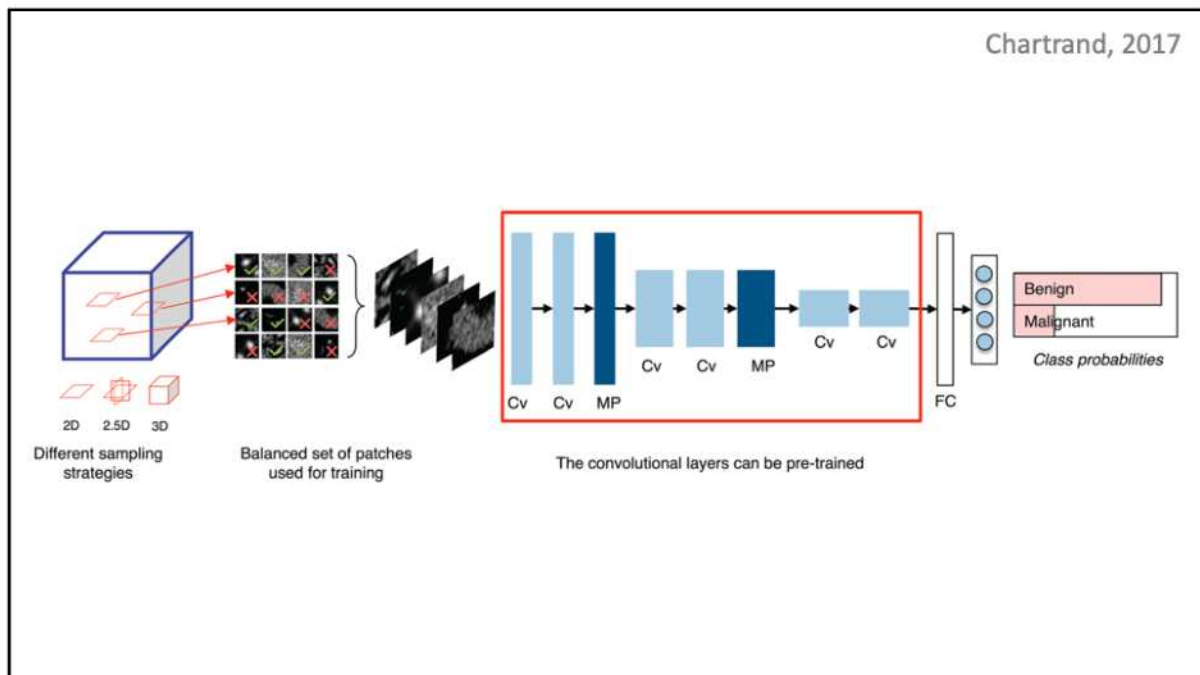
- Radioloogia on pildituvastus, ja keskne kihitüüp pildituvastuse aspektist on konvolutsioonikiht (convolution layer)
- Väike (nt 3×3) maatriks ehk tuum (*kernel*) liigub sammhaaval üle kogu vaatevälja. Igal sammul arvutatakse selle tuuma ning selle alla jäävate vaatevälja elemendi skalaarkorrutis ning see pannakse tuuma keskel asuva elemendi väärtuseks. Pärast $m \times m$ vaatevälja konvolutsiooni $n \times n$ tuumaga on tulemuseks $m \times m$ tunnuskaart (*feature map*), mis võib rõhutada näiteks struktuuride servi või mõnd muud tunnust. Tuumad on õpitavad, st nendega mängitakse masinõppe käigus
- Konvolutsioonikihte sisaldavaid närvivõrke nimetatakse ka konvolutsioonilisteks närvivõrkudeks (tõsijutt!)



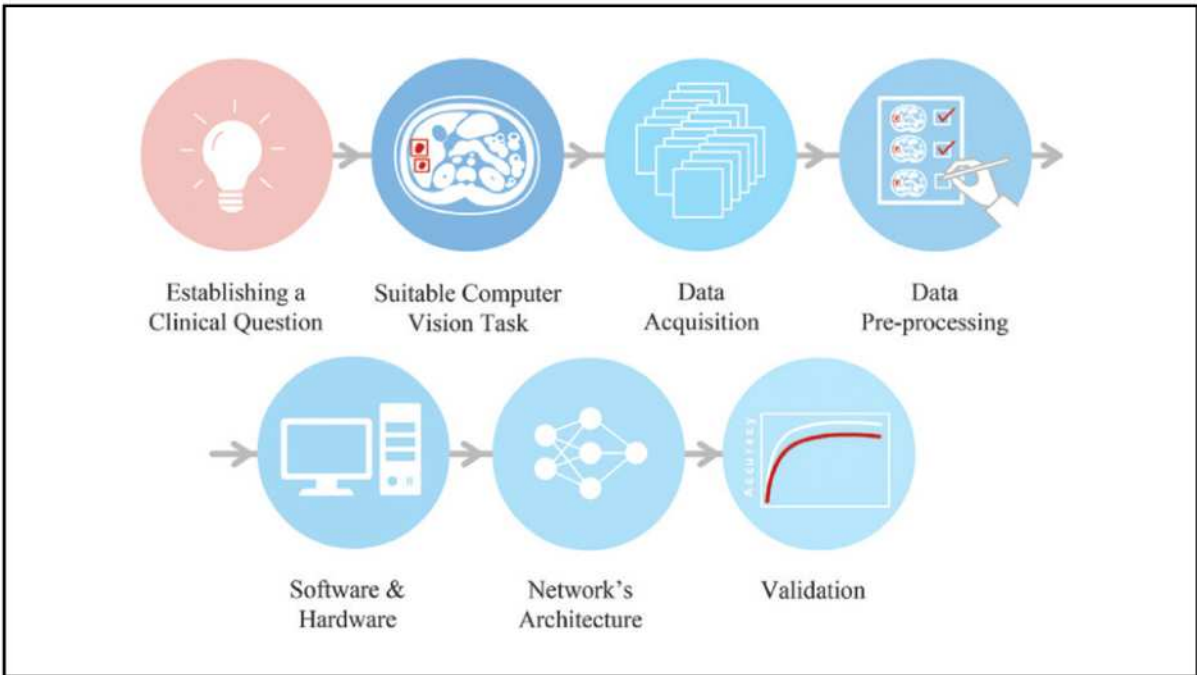
- Teist tüüpi kiht on ahenduskiht (*pooling layer*). Ahenduskiht võtab $m \times m$ vaatevälja ja liigub üle selle $n \times n$ tuumaga, vähendades vaatevälja suurust n korda nii, et igast $n \times n$ elemendist säilib nt maksimaalne (või keskmine) väärtus
- Sageli paiknevad konvolutsioonikihid ja ahenduskihid vaheldumisi. Kui sellele tegevusele lihtsustatult vaadata, siis pilt läheb kogu aeg väiksemaks ja koledamaks, aga üldistuse tase ning seega ka järelduste tegemise võimalus suuremaks



- Radioloogiliste andmetega töötades osutub kvaliteetsete andmete vähesus sageli probleemiks—liiati on meil ju vaja nii treening- kui valideerimisandmestikku
- Ülekandeõpe (*transfer learning*) kasutab ära asjaolu, et piltide üldised omadused—nt servad ja erinevused intensiivsuses—on suhteliselt sarnased pealtnäha väga erinevates andmestikes. Nii on täiesti mõeldav, et me trenime oma konvolutsioonilise närvivõrgu koerte, kasside, autode ja puude peal ning radioloogiale üle minnes kohandame lihtsalt närvivõrgu viimase, klassifitseeriva osa...



- Teine strateegia kvaliteetsete andmete vähesusega hakkama saamiseks on algandmetest fragmentide—nt beniigsete ja maliigsete kollete—välja lõikamine ja nende peal närvivõrgu treenimine. See võimaldab lahendada kaks probleemi: antu näite puhul saab ühelt uuritavalt sageli kätte mitu kollet, samal ajal saab tasakaalustada asjaolu, et beniigseid koldeid tuleb (õnneks) sagedamini ette kui maliigseid. Lõpuks võib seda lähenemist sama edukalt ülekandeõppega kombineerida



Kirjandus

- Chartrand G, Cheng PM, Vorontsov E, *et al.* Deep learning: a primer for radiologists. *RadioGraphics* 2017. DOI: [10.1148/rg.2017170077](https://doi.org/10.1148/rg.2017170077)
- Erickson BJ, Korfiatis P, Akkus Z, *et al.* Machine learning for medical imaging. *RadioGraphics* 2017. DOI: [10.1148/rg.2017160130](https://doi.org/10.1148/rg.2017160130)
- Soffer S, Ben-Cohen A, Shmion O, *et al.* Convolutional neural networks for radiologic images: a radiologist's guide. *Radiology* 2019. DOI: [10.1148/radiol.2018180547](https://doi.org/10.1148/radiol.2018180547)