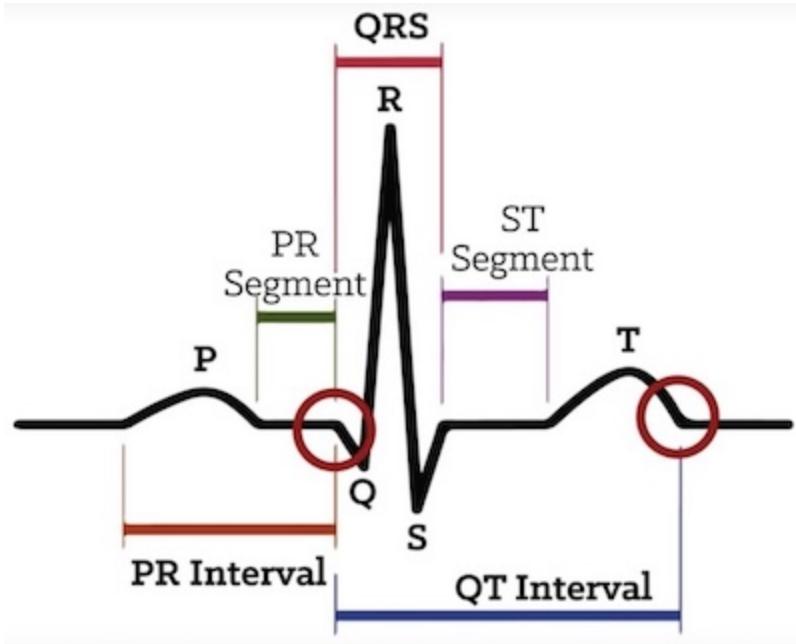


Čas, polno povezane nevronske mreže in konvolucijske mreže

Tokrat je naslov tega poglavja kar dolg, a snov morda niti ne preveč naporna. Ideja je, da posežemo po nekaterih tipičnih gradnikih nevronskih mrež in pričnemo sestavljati različne modele. Gradniki in zgradba mreže bo seveda odvisna od želene funkcije mreže, podobno bo od nje odvisen tudi tip kriterijske funkcije, ki jo bomo pri iskanju uteži optimizirali. Ukvajali se bomo kar s tremi različnimi nalogami: klasifikacijo, predstavljavo vhodnih podatkov (meritev) v vektorskem prostoru (angl. *embedding*) in generiranjem novih meritev (angl. *generative machine learning*). Da ne bo vse skupaj preveč v oblakih, bomo vse skupaj razvili na primeru. Tokrat bodo podatki meritve v času, oziroma časovne vrste. Tega do sedaj še nismo počeli: čeprav smo nize in časovne vrste omenili pri tipih podatkov na samem začetku semestra, smo potem obdelovali le podatke v atributnem zapisu, kjer smo predpostavili, da so atributi med seboj neodvisni in je bil rezultat strojnega učenja neodvisen od zaporedja atributov.

Podatki

EKG (elektrokardiogram) je meritev električne aktivnosti srca, ki jo izvajamo s postavljivoj elektrod na površino kože, običajno na prsni koš, roke in noge. Meritve se izvajajo v mirovanju, med telesno aktivnostjo ali ob sumu na srčne bolezni, saj EKG pomaga pri prepoznavanju motenj v srčnem ritmu in prevodnosti. Normalen EKG zapis prikazuje značilen vzorec valov: P-val (depolarizacija preddvorov), QRS-kompleks (hitro širjenje impulza in kontrakcija prekatov) ter T-val (ponovna repolarizacija prekatov).



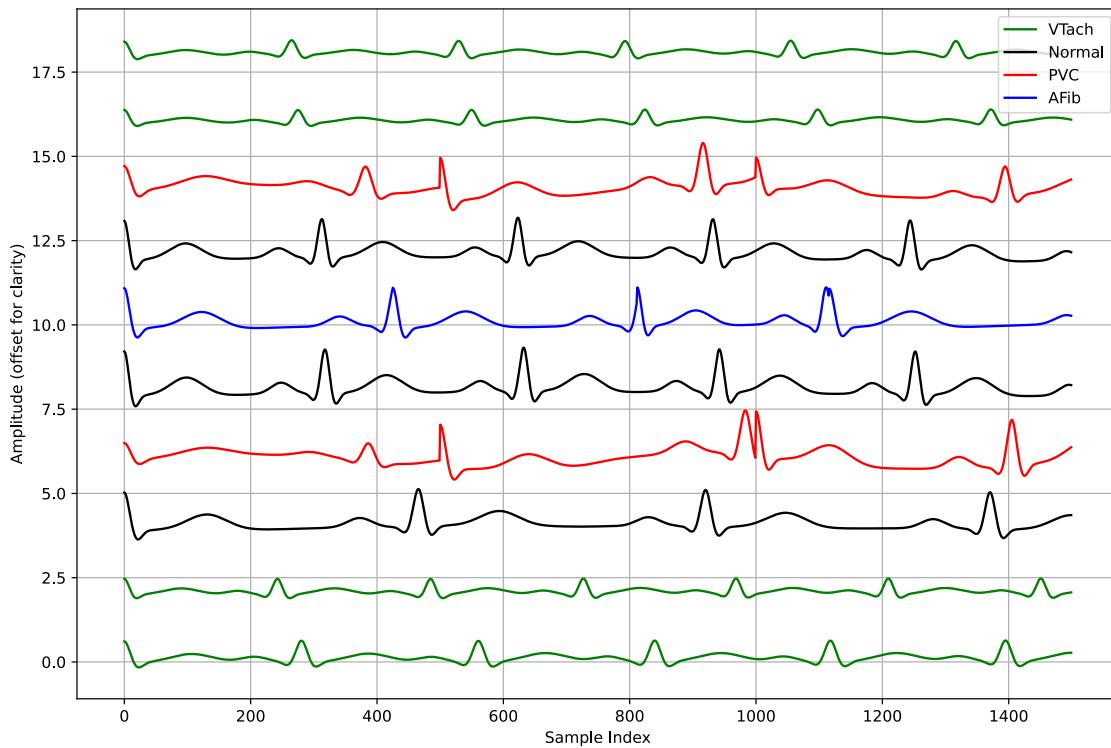
Slika: Tipičen EKG val z označenimi segmenti.

Srčne aritmije so odstopanja od običajnega ritma ali oblike teh valov, kar lahko kaže na prezgodnje utripe, počasno ali hitro bitje srca ali druge nepravilnosti v delovanju srčnega prevodnega sistema. Srčne aritmije so odstopanja od običajnega ritma ali oblike EKG valov, kar lahko kaže na prezgodnje utripe, počasno ali hitro bitje srca ali druge nepravilnosti v delovanju srčnega prevodnega sistema. Med pogostejšimi aritmijami so prezgodnji ventrikularni utripi (PVC), kjer prekat sproži utrip brez ustreznega signala iz preddvorov; atrijska fibrilacija, pri kateri preddvori trzajo namesto da bi se usklajeno krčili; bradikardija, kjer srce bije prepočasi; in tahikardija, kjer srce bije prehitro.

V tem poglavju bomo delali s simuliranimi EKG signali. (Veliko bolje bi sicer bilo delati s pravimi signali in uporabiti kakšno knjižnico z meritvami in anotacijami, a to prepustimo kakšni dobri diplomsk(i) nalogi.) Signale smo generirali s knjižnico `neurokit2`, ki omogoča realistično simulacijo EKG signalov z nadzorom nad parametri, kot so srčni utrip, šum, amplituda in oblika vala. Za prvi podatkovni nabor smo ustvarili dva razreda signalov: normalne EKG-je in signale z motnjo, imenovano prezgodnji ventrikularni utrip (PVC). Vsak signal je dolg 500 vzorcev in vsebuje tri zaporedne utripe; pri normalnih so vsi trije utripi običajni, pri motenih pa je eden od njih nadomeščen s širšim, manj izrazitim PVC utripom. Za zbirko, ki naj vsebuje različne signale, smo dodali tudi nekaj šuma in počasno nihanje osnovne črte kot posledica dihanja, da so podatki bolj podobni resničnim meritvam.

Drugi podatkovni nabor poleg zgornjih dveh razredov vsebuje tudi signale z atrijsko fibrilacijo

(AFib) in ventrikularno tahikardijo (VTach). Pri AFib gre za hitro in nepravilno bitje preddvorov brez jasnih P-valov, kar smo simulirali z nihanjem med naključno dolgimi srčnimi cikli. VTach pa je nevarna oblika tahikardije z visokim srčnim utripom, širokimi QRS kompleksi in pogosto zmanjšano amplitudo, ki smo jo ustvarili z raztezanjem in oslabljenjem osnovnega signala. Vsak razred vsebuje 250 signalov, skupaj 1000 primerov, ki jih lahko uporabimo za klasifikacijo več razredov, vizualizacijo v nizko-dimenzionalnih prostorih in generativno modeliranje.



Slika: Primeri generiranih signalov.

Generirali smo 300 različnih signalov za vsak razred podatkov. Podatke smo zapisali v dve NumPy strukturi: matrika `X` vsebuje signale, vektor `y` pa pripadajoče razrede. Vsak signal je dolg 450 točk (meritev), kar ustreza 3 sekundam vzorčenja pri 150 Hz. Matrika `X` ima pri varianti dveh razredov torej obliko `(600, 450)` – 300 normalnih in 300 PVC signalov. Vektor `y` vsebuje 600 celih števil, 0 za normalne in 1 za PVC primere. Za kasnejšo uporabo smo obe strukturi shranili v datoteko s funkcijo `np.savez`, kar omogoča enostavno nalaganje in uporabo v eksperimentih.

Opomba: koda za generiranje signalov je malce dolgočasna in je tu ne prikazujemo, je pa na voljo v spremljajočem repozitoriju kode za to poglavje.

Priprava podatkov za učenje

Pričnemo sicer z manj zanimivim delom: pripravo podatkov za uporabo v PyTorch knjižnici. Najprej postavimo razred, ki spremeni matrike in vektorja tipa NumPy v tenzorje:

```
class ToTensorDataset(Dataset):
    def __init__(self, X, y):
        self.X = torch.tensor(X, dtype=torch.float32)
        if self.X.ndim == 2:
            # dodaj dimenzijo kanala, če je potrebno
            self.X = self.X.unsqueeze(1)
        self.y = torch.tensor(y, dtype=torch.long)

    def __len__(self):
        return len(self.X)

    def __getitem__(self, idx):
        return self.X[idx], self.y[idx]
```

Razred `ToTensorDataset` pretvori vhodne podatke v matriki `X` in oznake v vektorju `y` v PyTorch tenzorje za nadaljnjo uporabo v modelih. Oznake `y` pretvorimo v tip `torch.long`, ker PyTorch funkcija izgube `CrossEntropyLoss`, ki se pogosto uporablja pri klasifikaciji, zahteva, da so razredi predstavljeni kot celoštevilski tenzor tipa `long`. Če je vhod `X` dvodimensionalen (npr. oblika `(n, d)`), funkcija `unsqueeze(1)` doda dodatno dimenzijo, s čimer dobimo obliko `(n, 1, d)`; to omogoča, da lahko podatke uporabimo kot enokanalne časovne vrste v konvolucijskih mrežah, ki pričakujejo vhod oblike `(batch_size, channels, length)`.

Podatke preberemo in jih pripravimo za učenje s spodnjim razredom:

```

class LoadData:
    def __init__(self, filename, batch_size=32):
        data = np.load(filename)
        X = data['X']
        y = data['y']
        self.batch_size = batch_size

        # razdelitev podatkov na učno in testno množico
        self.X_train, self.X_test, self.y_train, self.y_test = train_test_split(
            X, y, test_size=0.2, random_state=42, stratify=y
        )

        # določitev števila razredov
        self.num_classes = len(np.unique(y))

    def get_train_loader(self, ToTensorDataset):
        train_dataset = ToTensorDataset(self.X_train, self.y_train)
        train_loader = DataLoader(train_dataset, \
            batch_size=self.batch_size, shuffle=True)
        return train_loader

    def get_test_data(self, device=None):
        X_test_tensor = torch.tensor(self.X_test, dtype=torch.float32)
        if X_test_tensor.ndim == 2:
            X_test_tensor = X_test_tensor.unsqueeze(1)
        y_test_tensor = torch.tensor(self.y_test, dtype=torch.long)
        if device is not None:
            X_test_tensor = X_test_tensor.to(device)
            y_test_tensor = y_test_tensor.to(device)
        return X_test_tensor, y_test_tensor

    def get_num_classes(self):
        return self.num_classes

```

Razred `LoadData` je pomožni razred za nalaganje in pripravo podatkov za učenje in testiranje modelov v PyTorch okolju. Ob inicializaciji prebere podatke iz datoteke `.npz`, v kateri pričakuje dve spremenljivki: matriko `X` (vhodni signali) in vektor `y` (oznake razredov). Nato podatke razdeli na učno in testno množico v razmerju 80:20. Za razdelitev uporabi funkcijo `train_test_split` iz knjižnice `sklearn`, pri čemer stratificira razrede glede na razred, da se

ahrani njihova porazdelitev tudi po razdelitvi.

Metoda `get_train_loader` ustvari učni `DataLoader`, ki podatke ponudi v paketih. Uporabi razred `ToTensorDataset`, ki podatke pretvori v tenzorje.

Metoda `get_test_data` vrne testne podatke kot PyTorch tenzorje. Če so podatki dvodimenzionalni, se jim doda kanalna dimenzija z `unsqueeze(1)`, kar je potrebno za delo s konvolucijskimi modeli. Po potrebi se podatki prenesejo na določeno strojno opremo, če to uporabljamo (npr. GPU).

Metoda `get_num_classes` vrne število razredov v podatkih, kar je priročno za konfiguracijo modela.

Klasifikacija s polno povezanimi nivoji nevronske mreže

Tu smo pravzaprav že bili: naša nevronska mreža nekaj lekcij nazaj je služila transformaciji prostora tako, da je logistična regresija na koncu mreže lahko dobro ločila med razredi. Tudi tokrat ne bo prav drugače. Ta del zapiskov torej ponovi vajo, a tokrat na podatkih EKG meritev.

Uporabimo spodnji model:

```

class Model(nn.Module):
    def __init__(self, num_classes, signal_length):
        super().__init__()
        self.fc = nn.Sequential(
            nn.Linear(signal_length, 128),
            nn.ReLU(),
            nn.Linear(128, 64),
            nn.ReLU(),
            nn.Linear(64, num_classes)
        )

    def forward(self, x):
        # oblika x: [serija, 1, dolžina_signala] ali
        # [serija, dolžina_signala]
        x = x.view(x.size(0), -1) # splošči na [serija, dolžina_signala]
        return self.fc(x)

```

Gre za preprost nevronskega modela za klasifikacijo signalov, zgrajen kot t. im. večnivojska perceptronska mreža (angl. *multi-layered perceptron*). Razred dedujemo je iz razreda `nn.Module`, kar omogoča integracijo z ostalimi deli PyTorch okolja.

V konstruktorju `__init__` razred prejme število razredov (`num_classes`) in dolžino vhodnega signala (`signal_length`). Vhodni nivo je linearen (utežena vsota vhodov) z 128 nevroni, sledi aktivacijska funkcija ReLU, nato še en nivo z 64 nevroni in ponovno ReLU, ter na koncu izhodni nivo, ki ima toliko nevronov, kolikor je razredov. Ta zadnja plast vrača neskalarirane vrednosti (logite), ki jih uporabimo v funkciji izgube.

Torej ne uporabljam logistične regresije za klasifikacijo? Ni ravno res. Uporabili bomo ekvivalent logistične regresije, t. i. regresijo softmax, kjer bomo z ustreznim kriterijskim funkcijom poskrbeli, da bodo izhodi interpretirani kot verjetnosti. Konkretno, če je izhod modela vektor $z \in \mathbb{R}^C$, kjer je C število razredov, potem softmax funkcija pretvoriti ta vektor v verjetnosti po formuli:

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^C e^{z_j}}, \quad i = 1, \dots, C$$

Model sam tega ne izračuna, saj PyTorch funkcija izgube `CrossEntropyLoss` že vključuje softmax in log verjetnosti ter optimizira negativno log-verjetnost pravega razreda. Na ta način

dobimo večrazredno logistično regresijo – softmax regresijo – le da je pred njo večplastna nevronska mreža, ki signal najprej nelinearno transformira.

Funkcija `CrossEntropyLoss` meri razliko med napovedano verjetnostno porazdelitvijo in dejansko porazdelitvijo razredov, ki je v primeru klasifikacije predstavljena z eno vročo kodirano (one-hot) vektorjem cilja. Gre za standardno funkcijo izgube pri večrazredni klasifikaciji, ki je za en primer:

$$\mathcal{L}(x, y) = -\log \left(\frac{e^{x_y}}{\sum_{j=1}^C e^{x_j}} \right) = -x_y + \log \left(\sum_{j=1}^C e^{x_j} \right)$$

kjer so:

- $x = (x_1, x_2, \dots, x_C) \in \mathbb{R}^C$ je vektor logitov (izhodi modela pred softmaxom),
- $y \in \{1, \dots, C\}$ je indeks pravega razreda,
- C je število razredov.

Ta izraz združuje funkciji softmax in *negativno logaritem verjetnosti* v eno samo funkcijo, ki jo lahko učinkovito optimiziramo z gradientnim spustom. Pri učenju želimo minimizirati povprečno izgubo čez vse primere v učni množici.

`CrossEntropyLoss` je torej negativni logaritem napovedane verjetnosti pravega razreda, izračunane s softmax funkcijo. Če model za primer napove verjetnosti p_1, p_2, \dots, p_C , in je pravi razred y , potem je izguba:

$$\mathcal{L} = -\log(p_y)$$

To pomeni: čim manjšo verjetnost model pripisuje pravemu razredu, tem večja bo izguba. Model se torej uči tako, da povečuje verjetnost pravega razreda.

Omenimo naj še, da je funkcija softmax za dva razreda ekvivalentna logistični regresiji. V primeru dveh razredov je izhod modela vektor z dvema komponentama, npr. $z = (z_0, z_1)$. Softmax funkcija nato izračuna verjetnosti:

$$p_0 = \frac{e^{z_0}}{e^{z_0} + e^{z_1}}, \quad p_1 = \frac{e^{z_1}}{e^{z_0} + e^{z_1}}$$

Če definiramo razliko $a = z_1 - z_0$, lahko verjetnost za razred 1 izrazimo kot:

$$p_1 = \frac{1}{1 + e^{-a}}$$

To je ravno sigmoidna funkcija:

$$p_1 = \sigma(a) = \frac{1}{1 + e^{-a}}$$

kar je osnovna oblika logistične regresije. Torej, če model za dva razreda vrne logita z_0 in z_1 , je softmax klasifikacija ekvivalentna temu, da uporabimo sigmoidno funkcijo na razlike $z_1 - z_0$, kar je enako standardni binarni logistični regresiji.

Ostala nam je le še metoda `forward`. Ta določa, kako model obdeluje podatke. Ne glede na to, ali ima vhod obliko `[batch_size, 1, signal_length]` ali `[batch_size, signal_length]`, z ukazom `x.view(x.size(0), -1)` signal sploščimo v dvodimenzionalno obliko `[batch_size, signal_length]`, saj model ne uporablja konvolucij, temveč deluje na vektorjih. Rezultat `self.fc(x)` je izhod modela za vsak signal posebej.

Sledi koda za učenje. Tudi to smo delno že spoznali. V prevem delu pripravimo podatke, model, se odločimo za kriterijsko funkcijo in določimo, kako bomo izvajali optimizacijo.

```
loader = LoadData('ecg-two-classes.npz', batch_size=BATCH_SIZE)
num_classes = loader.get_num_classes()
signal_length = loader.X_train.shape[-1]
train_loader = loader.get_train_loader(ToTensorDataset)

model = Model(num_classes, signal_length)
criterion = nn.CrossEntropyLoss()
optimizer = torch.optim.Adam(model.parameters(), lr=LEARNING_RATE)
```

V drugem delu se naučimo uteži:

```

for epoch in range(EPOCHS):
    model.train()
    total_loss, correct, total = 0, 0, 0

    for X_batch, y_batch in train_loader:
        optimizer.zero_grad()
        outputs = model(X_batch)
        loss = criterion(outputs, y_batch)
        loss.backward()
        optimizer.step()

        total_loss += loss.item()
        _, predicted = torch.max(outputs.data, 1)
        total += y_batch.size(0)
        correct += (predicted == y_batch).sum().item()

    train_accuracy = 100 * correct / total
    print(f"Epoch {epoch+1}/{EPOCHS}, \
          Loss: {total_loss/len(train_loader):.4f}, "
          f"Train Accuracy: {train_accuracy:.2f}%")

```

Učenje nevronske mreže izvedemo skozi več epoh. Na začetku vsake epohe model preklopi v učeči način z `model.train()`, kar pomeni, da se aktivirajo mehanizmi, specifični za fazo učenja, kot sta *dropout* (za boljšo generalizacijo) in *batch normalization* (ki uporablja statistike trenutnega paketa). Nato se za vse pakete izvede standardni cikel učenja: najprej se ponastavijo gradienti (`optimizer.zero_grad()`), nato model izračuna napovedi za trenutni batch, izračuna se izguba (`loss = criterion(...)`), izvede povratno širjenje napake (`loss.backward()`) in posodobljanje uteži modela (`optimizer.step()`). V kodi tudi beležimo kumulativna izguba in natančnost napovedi glede na resnične razrede. Povprečje teh izpišemo na koncu.

Rezultate učenje preverimo na testni množici:

```

model.eval()
with torch.no_grad():
    X_test_tensor, y_test_tensor = loader.get_test_data()
    outputs = model(X_test_tensor)
    _, predicted = torch.max(outputs, 1)
    accuracy = (predicted == y_test_tensor).float().mean().item()
print(f"Test accuracy: {accuracy:.4f}")
print(f"Test loss: {loss:.4f}")
print("Confusion matrix:")
print(confusion_matrix(y_test_tensor.numpy(), predicted.numpy()))

```

Konvergenca je tako pri dvorazredni kot štirirazredni množici podatkov hitra, rezultati pa, skoraj malce presentljivo, odlični:

```

Test accuracy: 0.9750
Test loss: 0.0000
Confusion matrix:
[[60  0  0  0]
 [ 0 60  0  0]
 [ 3  0 54  3]
 [ 0  0  0 60]]

```

Razlog za tako odlične rezultate je prav gotovo v veliki podobnosti signalov v učni in testni množici. Pri pravih podatkih bi se morali npr. učiti na eni množici preiskovancev, testirali pa bi na drugih preiskovancih in tu rezultati prav gotovo ne bi bili tako dobri.

Zaključimo le še z razmišljanjem o kompleksnosti tovrstnega modela. Dolžina vsakega vhodnega EKG signala je 450 točk. Model ima tri popolnoma povezane (linearne) plasti, vsaka s svojimi utežmi in pristranskostmi (bias).

1. Prvi nivo: nn.Linear(450, 128)

Ta nivo pretvori vhodni signal dolžine 450 v vektor dolžine 128.

- Matrika uteži: (128, 450)
- Pristranskosti: (128,)
- Skupno število parametrov: $128 \times 450 + 128 = 57.728$

2. Drugi nivo: nn.Linear(128, 64)

Pretvori 128-dimenzionalen vektor v vektor dolžine 64.

- Matrika uteži: (64, 128)
- Pristranskosti: (64,)
- Skupno število parametrov: $64 \times 128 + 64 = 8.256$

3. **Tretji nivo:** `nn.Linear(64, 4)` (ker imamo 4 razrede)

Pretvori 64-dimenzionalen vektor v 4 logite, ki jih interpretiramo kot verjetnosti za posamezni razred.

- Oblika uteži: (4, 64)
- Oblika pristranskosti: (4,)
- Skupno število parametrov: $4 \times 64 + 4 = 260$

Skupno število parametrov je zato:

$$57.728 + 8.256 + 260 = 66.244$$

Te uteži so shranjene v modelu kot tenzorji, povezani z vsakim slojem, in se med učenjem prilagajajo. Lahko jih izpišemo z ukazom:

```
for name, param in model.named_parameters():
    print(name, param.shape)
```

Dobimo:

```
fc.0.weight torch.Size([128, 450])
fc.0.bias torch.Size([128])
fc.2.weight torch.Size([64, 128])
fc.2.bias torch.Size([64])
fc.4.weight torch.Size([4, 64])
fc.4.bias torch.Size([4])
```

Število parametrov lahko izračunamo tudi z malce programiranja, brez, da bi računali ročno:

```
print("\nNumber of parameters in each layer:")
total_params = 0
for name, param in model.named_parameters():
    if param.requires_grad:
        num_params = param.numel()
        print(f"{name}: {num_params},")
        total_params += num_params
print(f"Total trainable parameters: {total_params}")
```

Konstrukt `if param.requires_grad:` je tu za vsak slučaj, saj so vsi parametri modeli taki, da za njih računamo gradiente. Z `param.numel()` dobimo število elementov (parametrov) v danem PyTorch tenzorju. Koda izpiše:

```
Number of parameters in each layer:
fc.0.weight: 57,600
fc.0.bias: 128
fc.2.weight: 8,192
fc.2.bias: 64
fc.4.weight: 256
fc.4.bias: 4
Total trainable parameters: 66,244
```

Podobno, torej, kar smo računali peš že zgoraj.

Klasifikacija s konvolucijsko nevronsko mrežo

Model s polno povezanimi nivoji je kompleksen, in bi bil še kompleksnejši, če bi uporabili ali časovno daljše vhodne signale ali pa če bi bolj pogosto vzorčili. Tudi v namene zmanjšanja te kompleksnosti, pa tudi zaradi tega, ker bi bilo prav, da se na vhodnem delu mreže nevroni osredotočijo le na del vhodnega signala, je bila predlagana [t.im](#). konvolucijska nevronska mreža. Začnimo kar z modelom:

```

class Model(nn.Module):
    def __init__(self, num_classes):
        super().__init__()
        self.conv_layers = nn.Sequential(
            # prvi konvolucijski blok
            nn.Conv1d(1, 16, kernel_size=5, stride=3, padding=2),
            nn.BatchNorm1d(16),
            nn.ReLU(),
            nn.MaxPool1d(kernel_size=2),

            # drugi konvolucijski blok
            nn.Conv1d(16, 16, kernel_size=5, stride=3, padding=2),
            nn.BatchNorm1d(16),
            nn.ReLU(),
            nn.AdaptiveAvgPool1d(1) # globalno povprečno združevanje
        )

        # popolnoma povezane plasti
        self.fc = nn.Sequential(
            nn.Linear(16, 16),
            nn.ReLU(),
            nn.Linear(16, num_classes)
        )

    def forward(self, x):
        x = self.conv_layers(x)
        x = x.view(x.size(0), -1)
        return self.fc(x)

```

Konvolucijska nevronska mreža (CNN) temelji na ideji, da se posamezni nevroni ne povežejo z vsemi vhodi, temveč le z lokalnim delom vhodnega signala. To omogoča učinkovitejše učenje, saj se mreža osredotoči na lokalne vzorce, ki se v signalu lahko pojavljajo na različnih mestih. Takšna arhitektura je posebej primerna za obdelavo časovnih vrst, kot je EKG, kjer nas zanimajo lokalni dogodki, kot so posamezni utripi ali njihova deformacija.

Osnovna gradnika CNN sta konvolucijska plast in funkcija združevanja. Konvolucija v enodimenzionalnem primeru pomeni, da skozi signal premikamo majhno okno (filter ali jedro) in za vsak položaj izračunamo uteženo vsoto. Matematično je izhod konvolucije podan z:

$$y[n] = \sum_{k=0}^{K-1} x[n-k] \cdot w[k]$$

Kjer je $x[n]$ vhodni signal, $w[k]$ uteži filtra dolžine K , in $y[n]$ izhodni signal. V PyTorchu plast `nn.Conv1d` takih filtrov ustvari več hkrati, vsak z lastnimi utežmi. V našem primeru prvi konvolucijski sloj uporabi 16 filtrov dolžine 5 nad enokanalnim signalom in s tem izdela 16 novih kanalov, ki vsak poudarijo določene vzorce v signalu.

Plast `nn.Conv1d(1, 16, kernel_size=5, stride=3, padding=2)` je enodimensionalna konvolucijska plast, ki vhodni enokanalni signal pretvori v 16 izhodnih kanalov z uporabo 16 različnih filtrov dolžine 5. Parameter `kernel_size=5` določa velikost filtrov, ki pokrivajo 5 zaporednih točk signala, `stride=3` pomeni, da se filter pomika po signalu v korakih po 3 točke, kar zmanjša dolžino izhoda, in `padding=2` doda 2 ničli na začetek in konec signala, da filter lahko deluje tudi na robovih. Ta plast bo pretvorila vhod oblike `[batch, 1, 500]` v izhod oblike `[batch, 16, 167]`, saj se dolžina signala z zmanjšanjem zaradi koraka 3 zmanjša približno na tretjino ($500/3 \approx 167$).

`nn.BatchNorm1d(16)` normalizira vrednosti v vseh 16 kanalih tako, da imajo povprečje približno 0 in standardni odklon približno 1, kar prispeva k stabilnejšemu in hitrejšemu učenju; `nn.ReLU()` doda nelinearnost tako, da negativne vrednosti nadomesti z ničlo; `nn.MaxPool1d(kernel_size=2)` pa prepolovi dolžino signala, saj iz vsakega zaporednega para vrednosti izbere največjo, s čimer zmanjša dimenzionalnost in poudari najizrazitejše lokalne značilnosti.

Če je vhodna oblika signala `[batch, 1, 450]` (kjer je batch število primerov v paketu, pri nas 32), potem so dimenzijs izhoda po prvem nivoju naslednje:

1. `nn.Conv1d(1, 16, kernel_size=5, stride=3, padding=2)`

Ta plast zgradi torej 16 različnih filtrov, vsek dolžine 5, torej 80 uteži s 16 začetnimi vrednostmi. Ko filtre apliciramo na vhodni signal, se nam na izhodu dolžina vektorjev zmanjša iz vhodnih 450 na 150, a je teh 16, kar ustreza 16 izhodnim kanalom, po en za vsak filter:

$$\left\lfloor \frac{450 + 2 \cdot 2 - 5}{3} \right\rfloor + 1 = \left\lfloor \frac{449}{3} \right\rfloor + 1 = 149 + 1 = 150$$

Oblika izhoda je torej `[batch, 16, 150]`.

2. Operaciji `nn.BatchNorm1d(16)` in `ReLU()` ne spremenita oblike, njun izhod je še

vedno oblike **[batch, 16, 150]**. Sloj `nn.BatchNorm1d(16)` doda 2 parametra na kanal (skaliranje in premik), torej vse skupaj $2 \times 16 = 32$ parametrov. Plast `ReLU()` ne doda nobenih parametrov.

3. Plast `nn.MaxPool1d(kernel_size=2)` v vsakem kanalu vzame dve zaporedni vrednosti in vrne večjo vrednost. V vsakem kanalu torej prepolovi dolžino signala. Končna oblika podatkov po prvem konvolucijskem nivoju je torej `[batch, 16, 75]`.

$$\left\lfloor \frac{150}{2} \right\rfloor = 75$$

Drugi konvolucijski blok še dodatno obdeluje nastalih 16 kanalov dolžine 75 z novimi 16 filterji dolžine 5, pri čemer se signal zaradi `stride=3` dodatno skrči. Sledi normalizacija in nelinearnost, nato pa `AdaptiveAvgPool1d(1)`, ki vsak kanal povpreči po celotni dolžini in rezultat skrči v obliko `[batch, 16, 1]`, kar omogoča fiksno velik izhod, neodvisen od dolžine signala.

4. `nn.Conv1d(16, 16, kernel_size=5, stride=3, padding=2)`

Ta plast prejme 16 vhodnih kanalov in za vsak izhodni kanal zgradi 16 filtrov (po enega za vsak vhodni kanal), torej skupaj $16 \times 16 \times 5 = 1280$ uteži in dodatnih 16 začetnih vrednosti. Vsak izhodni kanal ima torej en filter dimenzije 16×5 , torej $16 \times 5 = 80$ uteži ter eno skupno začetno vrednost.

Vhodna dolžina je 75 (iz prejšnje plasti), zato bo dolžina na izhodu:

$$\left\lfloor \frac{75 + 2 \cdot 2 - 5}{3} \right\rfloor + 1 = \left\lfloor \frac{74}{3} \right\rfloor + 1 = 24 + 1 = 25$$

Oblika izhoda je torej **[batch, 16, 25]**, kjer imamo ponovno 16 kanalov (en za vsak nov filter) in na vsakem niz (vektor) s 25 elementi

5. Operaciji `nn.BatchNorm1d(16)` in `ReLU()` ne spremenita oblike — izhod je še vedno **[batch, 16, 25]**.

`BatchNorm1d(16)` doda še enkrat $2 \times 16 = 32$ parametrov, `ReLU()` ne doda nič.

6. Plast `nn.AdaptiveAvgPool1d(1)` povpreči vrednosti v vsakem kanalu vzdolž zadnje dimenzije dolžine 25 in iz nje vrne le povprečno vrednost kanala. Izhodna oblika postane **[batch, 16, 1]**. Ta plast nima parametrov, saj gre samo za povprečenje — iz vsakega kanala ta plast naredi **povzetek** (povprečje) po času. V imenu je `Adaptive` saj ta plast računa povprečje po segmentih vhodnega signala

tako, da vedno vrne signal želene dolžine `output_size`, ne glede na vhodno dolžino. Tu je parameter `1`, a če bi bil npr. `4`, bi plast samodejno razdelila signal na 4 enakomerne segmente po 25 vrednosti in vrnila štiri povprečja na kanal, torej [batch, 16, 4].

Del `self.fc` je zaključni klasifikacijski del mreže. Prva plast `nn.Linear(16, 16)` prejme 16 povprečnih vrednosti (po ena za vsak kanal) in jih pretvori v nov 16-dimenzionalni predstavitevni vektor. `ReLU()` doda nelinearnost, nato pa `nn.Linear(16, num_classes)` pretvori ta vektor v toliko logitov, kolikor je razredov. Ti logiti se nato uporabijo v funkciji izgube (npr. `CrossEntropyLoss`) za izračun napake in učenje modela.

Celoten model je odvisen od (samo!) 1796 parametrov. Primerjajmo z mrežo iz prejšnjega poglavja, s skoraj 40-krat več parametri! Prva konvolucijska plast ima 96 parametrov, druga 1296, vsaka normalizacija po 32. Popolnoma povezani del doda še 272 parametrov v prvi linearne plasti in 68 v izhodni (pri 4 razredih). Gre za lahek model, primeren za klasifikacijo krajsih časovnih signalov (koda za izpis števila parametrov po nivojih mrež je enaka kot pri polno povezani nevronski mreži):

```
Number of parameters in each layer:  
conv_layers.0.weight: 80  
conv_layers.0.bias: 16  
conv_layers.1.weight: 16  
conv_layers.1.bias: 16  
conv_layers.4.weight: 1,280  
conv_layers.4.bias: 16  
conv_layers.5.weight: 16  
conv_layers.5.bias: 16  
fc.0.weight: 256  
fc.0.bias: 16  
fc.2.weight: 64  
fc.2.bias: 4  
Total trainable parameters: 1,796
```

Funkcija `forward` določa, kako model obdeluje vhodne podatke. Najprej `x` (vhodni signal oblike [batch, 1, length]) potuje skozi konvolucijske plasti (`self.conv_layers`), kjer se izračunajo lokalne spremenljivke in zmanjša dimenzija. Nato se rezultat preoblikuje z `x.view(x.size(0), -1)` v matriko oblike [batch, features], torej splošči vse dimenzije

razen velikosti paketa. Na koncu se ta vektor pošlje polno povezanim plastem (`self.fc`), ki vrnejo logite za razvrščanje v razrede.

Del z učenjem in vrednotenjem ostane enak. Kar je odlično, saj smo tu zato le spremenili model. Konvergenca je tu sicer malce počasnejša, a so rezultati tipično dobri:

```
Test accuracy: 0.9875
```

```
Test loss: 0.0249
```

```
Confusion matrix:
```

```
[[60  0  0  0]
 [ 0 60  0  0]
 [ 3  0 57  0]
 [ 0  0  0 60]]
```