

De Deep-CW-Decoder

Neurale netwerken voor real-time morse-decodering onder ruis en QSB

1. Inleiding

Morsecode (CW – 'continuous wave') is al meer dan een eeuw een van de meest robuuste communicatievormen in de radioamateurwereld. Een CW-signaal bestaat in essentie uit niets meer dan een draaggolf die aan- en uitgeschakeld wordt volgens een tijdscode. Juist die eenvoud maakt CW extreem bandbreedte-efficiënt en goed hoorbaar bij zeer lage signaal-ruisverhoudingen (SNR) — vaak nog leesbaar voor het menselijk oor ver onder het punt waar spraak- of digitale modes onbruikbaar worden.

Het automatisch decoderen van CW door software is echter historisch gezien een lastig probleem gebleken. Klassieke decoders, gebaseerd op envelopdetectie en vaste of adaptieve drempelwaarden, presteren goed bij een schone, sterke draaggolf met een stabiele zendsnelheid, maar vallen snel terug bij ruis, fading (QSB), interferentie van naburige signalen, of bij operators met onregelmatige 'fist' (handschrift). Dit artikel behandelt de nieuwe generatie CW-decoders die dit probleem aanpakken met deep learning: de zogeheten Deep-CW-Decoder-aanpak, met als concreet voorbeeld het open-source project DeepCW.

2. De beperkingen van klassieke CW-decoders

Traditionele CW-decoders werken doorgaans volgens een vast stramien:

- Signaal wordt gefilterd rond de vermoede toonfrequentie (meestal met een smalle bandpassfilter of Goertzel-algoritme).
- De envelope van het gefilterde signaal wordt gedetecteerd (bijvoorbeeld via een gelijkrichter en laagdoorlaatfilter).
- Een drempelwaarde — vaak dynamisch bijgesteld met AGC — bepaalt of het signaal 'aan' (mark) of 'uit' (space) is.
- De duur van marks en spaces wordt vergeleken met een geschatte elementlengte (de 'dot-tijd') om punten, strepen en woord-/tekenpauzes te onderscheiden.
- Een tabel met Morse-patronen zet de herkende punt/streep-reeksen om in tekens.

Dit pijlpijn-model werkt goed zolang elke stap correct is, maar de stappen zijn sterk van elkaar afhankelijk: een verkeerd geschatte drempelwaarde leidt tot verkeerde elementduren, wat weer leidt tot verkeerde tekenherkenning. Bij een dalende SNR, snel fadende signalen (QSB), gelijktijdige signalen op naburige frequenties, of sprongen in de zendsnelheid (bijvoorbeeld bij handmatig seinen) stapelen kleine fouten in elke stap zich op. Het resultaat is dat klassieke decoders vaak abrupt instorten: boven een bepaalde SNR-drempel werken ze vrijwel foutloos, eronder wordt de uitvoer al snel onleesbaar.

3. De deep learning-aanpak

Deep-CW-decoders verlaten het strikt sequentiële pijplijn-model en vervangen het geheel of gedeeltelijk door een neurale netwerk dat direct leert om een audiofragment (of het spectrogram daarvan) af te beelden op een tekenreeks. Er zijn twee sleutelideeën die dit mogelijk maken.

3.1 Spectrogram als invoerrepresentatie

In plaats van het audiosignaal in het tijdsdomein te analyseren, zetten de meeste deep-CW-systemen het signaal eerst om in een spectrogram: een tijd-frequentiebeeld verkregen via een Short-Time Fourier Transform (STFT). Dit geeft het netwerk toegang tot zowel de temporele structuur (aan/uit-patroon) als de frequentie-inhoud, wat helpt om het CW-signaal te onderscheiden van smalbandige ruis, andere signalen in de band, en atmosferische storing. Het spectrogram wordt behandeld als een beeld met vaste hoogte (frequentiebins) en variabele breedte (tijdstappen).

3.2 Convolutionele en recurrente lagen

Een veelgebruikte architectuur — toegepast in verschillende open-source implementaties zoals die van AG1LE en vergelijkbare projecten — combineert:

- Convolutionele lagen (CNN) die lokale tijd-frequentiepatronen herkennen: de karakteristieke 'blokjes' van een dot of dash in het spectrogram, ongeacht kleine verschuivingen in tijd of frequentie.
- Recurrente lagen (LSTM of GRU) die de volgorde van deze lokale patronen over een langere tijdspanne modelleren, zodat het netwerk context opbouwt over meerdere elementen, tekens en woorden.
- Een Connectionist Temporal Classification (CTC) uitvoerlaag, die het mogelijk maakt om een variabele-lengte audiofragment direct te koppelen aan een tekenreeks zonder dat er vooraf een exacte uitlijning tussen audio-tijdstappen en tekens nodig is.

De CTC-laag is architectonisch cruciaal: bij klassieke decoders moet de exacte grens tussen elk Morse-element vooraf correct bepaald worden. CTC laat het netwerk zelf leren waar de grenzen liggen, inclusief het omgaan met variabele zendsnelheid, onregelmatige pauzes en zelfs een zekere mate van 'slordig' seinen — zaken waar drempelwaarde-gebaseerde methoden juist op struikelen.

3.3 Training op synthetische en reële data

Omdat handmatig gelabelde CW-opnames schaars zijn, wordt het gros van de trainingsdata synthetisch gegenereerd: tekst (bijvoorbeeld uit ARRL-oefenbestanden of QSO-logboeken) wordt omgezet naar Morse-audio, waarna programmatisch ruis, fading, frequentie-drift, timing-jitter en interfererende signalen worden toegevoegd. Zo kan een netwerk getraind worden op tienduizenden uren gevarieerde audio, met exacte controle over de SNR en andere kanaaleigenschappen — iets wat met alleen opgenomen QSO's niet haalbaar zou zijn. Een deel van de trainingsset bestaat doorgaans ook uit reële, off-air opgenomen CW-QSO's om het model te laten generaliseren naar echte omstandigheden zoals propagatie-effecten en variatie in operator-'fist'.

4. Praktijkvoorbeeld: het DeepCW-project

Een concreet en publiek beschikbaar voorbeeld van deze aanpak is het open-source project DeepCW (ontwikkeld door de GitHub-gebruiker e04, beschikbaar als webapplicatie). Het project positioneert zich als een 'ultra-accurate, real-time' CW-decoder die volledig op een neurale netwerkmodel draait. Enkele kenmerken:

- Real-time decodering in de browser, zonder dat audio naar een externe server gestuurd hoeft te worden.
- Robuuste decodering bij zwakke signalen, QSB (fading) en ruisige condities — juist de scenario's waarin klassieke decoders falen.
- Meerkanaals decodering, waarbij meerdere gelijktijdige CW-signalen binnen dezelfde waterval afzonderlijk herkend en gedecodeerd kunnen worden.
- Audio-doorvoer met neurale ruisonderdrukking, zodat een operator het gefilterde signaal ook met het oor kan blijven volgen terwijl de tekst wordt gedecodeerd.
- Multiplatform beschikbaarheid via de browser, met ondersteuning op desktop- en mobiele besturingssystemen.

4.1 Gepubliceerde prestaties

De ontwikkelaar publiceerde benchmarkresultaten uitgedrukt in Character Error Rate (CER) — het percentage ingevoegde, verwijderde of vervangen tekens ten opzichte van de referentietekst — gemeten over een bandbreedte van 2500 Hz en over een reeks zendsnelheden. De gerapporteerde resultaten laten een nagenoeg foutloze decodering zien tussen 0 en -4 dB SNR, met een geleidelijke (in plaats van abrupte) toename van de foutmarge bij zwakkere signalen. Onderstaande tabel geeft de globale trend weer zoals gerapporteerd:

SNR (dB)	10–15 WPM	20–25 WPM	30+ WPM
0 tot -4	0,0%	0,0%	0,0%
-6	≈0%	< 0,5%	< 1%
-8	< 1%	< 1,5%	< 1,5%
-10	< 5%	< 8%	< 8%

Tabel 1 — Globale trend van de gerapporteerde Character Error Rate (CER) als functie van SNR en zendsnelheid (bron: projectdocumentatie van DeepCW).

Opvallend is dat de foutmarge ook bij -8 dB SNR nog ruim onder de 2% blijft, en zelfs bij -10 dB — een niveau waarop een signaal voor een onervaren luisteraar nauwelijks nog als CW herkenbaar is — de fout beperkt blijft tot enkele procenten, in plaats van de volledige onleesbaarheid die klassieke decoders op dat niveau doorgaans vertonen.

4.2 Vergelijking met bestaande decoders

Het project vergeleek zijn resultaten met drie gevestigde decoders: CW Skimmer, fldigi en ggmorse, aan de hand van publiek beschikbare korte CW-QSO-fragmenten. Bij signalen met een redelijke SNR presteerden alle vier de decoders vergelijkbaar, maar bij zwakkere of ruisigere fragmenten liep de neurale decoder duidelijk voor: waar de klassieke decoders karakters begonnen te missen, te verzinnen of te verhaspelen bij overlappende ruis, bleef de tekstuitvoer van de neurale decoder grotendeels intact en leesbaar. De onderstaande tabel vat het kwalitatieve verschil samen.

Decoder	Aanpak	Gedrag bij zwak signaal / QSB	Meerkanaals
CW Skimmer	DSP / drempelwaarde + heuristiek	Degradeert snel onder ca. -4 dB SNR	Ja (breedband)
fldigi	Envelopdetectie + timing-analyse	Gevoelig voor ruis en onregelmatige keying	Nee
ggmorse	Klassieke signaalverwerking, open source	Matig robuust, moeite met QSB	Nee
Deep-CW-Decoder	Neuraal netwerk (CNN/RNN + CTC)	Blijft vrijwel foutloos tot -6 dB, geleidelijke degradatie	Ja

Het is belangrijk hierbij te vermelden dat dit soort vergelijkingen sterk afhankelijk is van de gebruikte testclips, instellingen en het gehanteerde beoordelingsproces, en dus niet als een algemene, universele rangschikking van deze programma's gelezen moet worden. Niettemin geeft het een representatief beeld van de meerwaarde die een deep learning-model kan bieden onder marginale ontvangstcondities.

5. Meerkanaals decoding

Een van de praktisch interessantste mogelijkheden van een neurale aanpak is meerkanaals decoding: het gelijktijdig herkennen en decoderen van meerdere CW-signalen die zich op verschillende toonfrequenties binnen dezelfde ontvangstbandbreedte bevinden. Bij een klassieke decoder vereist dit doorgaans een aparte filter- en detectieketen per kanaal, met alle risico's op onderlinge interferentie tussen dicht opeengepakte signalen. Een op spectrogrammen trainend neurale netwerk kan daarentegen in principe leren om de spectrale 'vingerafdruk' van elk signaal afzonderlijk te herkennen, ook wanneer signalen elkaar in tijd en frequentie gedeeltelijk overlappen — vergelijkbaar met hoe zulke netwerken in spraakherkenning worden ingezet om overlappende sprekers te scheiden.

6. Beperkingen en aandachtspunten

- Rekenkracht: hoewel inferentie op moderne hardware (inclusief in de browser via WebAssembly of WebGPU) real-time haalbaar is, vraagt training van dit soort modellen aanzienlijk meer rekenkracht dan het schrijven van een klassieke drempelwaarde-decoder.
- Generalisatie: de kwaliteit van een neurale decoder hangt sterk af van de diversiteit van de trainingsdata; ongebruikelijke keying-stijlen, extreem hoge snelheden, of signaaltypen die niet in de trainingsset voorkwamen, kunnen tot onverwachte fouten leiden.
- Uitlegbaarheid: waar een klassieke decoder stap voor stap te volgen is (en dus goed te debuggen), is het gedrag van een neurale netwerk minder transparant, wat foutanalyse lastiger maakt.
- Afhankelijkheid van representatieve benchmarks: prestatievergelijkingen zijn sterk afhankelijk van de gekozen testset; resultaten op enkele YouTube-fragmenten zijn illustratief maar geen volledig gecontroleerde wetenschappelijke evaluatie.

7. Conclusie

De opkomst van deep learning-gebaseerde CW-decoders zoals DeepCW markeert een duidelijke stap voorwaarts ten opzichte van de klassieke envelopdetectie- en drempelwaardemethoden die decennialang de standaard vormden. Door een CW-signaal te benaderen als een sequentie-tot-sequentie probleem — met een spectrogram als invoer, convolutionele en recurrente lagen voor patroon- en contextherkenning, en een CTC-uitvoerlaag voor alignment-vrije decoding — slagen deze systemen erin om aanzienlijk robuuster te blijven bij zwakke signalen, QSB en ruis dan hun klassieke voorgangers. Voor de radioamateur die geregeld in marginale condities CW probeert te kopiëren, bijvoorbeeld tijdens DX-pileups of bij zwakke propagatie, betekent dit een praktisch bruikbaar hulpmiddel dat een klassieke decoder op vrijwel elk vlak overtreft, met als bijkomend voordeel dat de onderliggende technologie zich ook goed leent voor uitbreidingen zoals meerkanaals decoding en geïntegreerde ruisonderdrukking.

Bronnen

Projectdocumentatie van DeepCW (e04/web-deep-cw-decoder), GitHub — geraadpleegd juli 2026.

Algemene achtergrond over CNN-LSTM-CTC-architecturen voor Morse-decodering, zoals beschreven in publieke blogposts en open-source projecten over deep learning-gebaseerde Morse-decoders (o.a. AG1LE, VE3NEA/DeepCW).

Ter verduidelijking :

Convolutionele lagen vormen de kern van Convolutional Neural Networks (CNN's) en worden voornamelijk gebruikt voor beeldherkenning en patroon analyse

Reccurente lagen zijn onderdelen in kunstmatige neurale netwerken (AI) die sequentiële data verwerken door informatie uit eerdere stappen te onthouden

Een Connectionist Temporal Classification is een algoritme en verliesfunctie (loss function : meet hoe goed een machine learning-model presteert). Het berekent het verschil tussen de voorspelling van het model en de werkelijke waarde

Onderstaand vindt je de Hyperlink van 04/web-deep-cw decoder :

<https://www.bing.com/ck/a?!&&p=e12297a825c1d7391307b10a66b644402b737ee27109f6ac379f50b0970b5787JmltdHM9MTc4MzcyODAwMA&ptn=3&ver=2&hsh=4&fclid=2d8149e8-2a1b-6030-10e8-5faa2b696116&psq=o4+deep+cwdecoder&u=a1aHR0cHM6Ly9naXRodWIuY29tL2UwNC93ZWltZGVlcC1jdy1kZWVvZGVy&ntb=1>

Lees het artikel en aanvullend kan je dan met de Web based “DeepCw” versie het eens uitproberen...

stap 1 : zie : DEEP CW en Launch DeepCW : <https://cw.e04.workers.dev/>

stap 2 : Instellingen voor de Icom IC-7300 - Audio-uitgang (USB-instellingen) :

Menu> Set > Connect > USB Audio SQL, zet deze op OFF (open)

Menu > Set > Connect > ACC/USB Output Level, 50%

Menu > Set > Connect > Data Off Mode, zet deze op Mic,ACC of Mic,USB

Stap 3 : Instellingen voor “IC-7300” en “DeepCW”:

IC-7300 Uitvoer LS (USB Audio Codec)

IC-7300 Invoer Cable Output (VB-Audio Virtual Cable)

In DeepCW : Idem

Stap 4: Run de decoder,

Have Fun with this new fantastic tool

ON5QM – Paul De Caluwe

de.caluwe.paul@skynet.be