Datoriserad signalbehandling

I traditionell diagnostik tas signalen ut på en pappersremsa för att studeras av en läkare. Men vad kan man göra med hjälp av en dator? Kan man vinna något på att låta sampla signalen och stoppa in den i en dator för bearbetning eller ökar risken för feldiagnoser? Detta är några frågeställningar jag tänkt behandla här.

För att kunna datorbearbeta signalen överhuvudtaget krävs att vi har eller kan skapas oss en signal i för datorn läsbart format. Detta åstadkomms med sampling av signalen. Sampling ger oss en digital signal i tidsplanet. I tidsplanet kan man i princip göra samma saker som man för hand kan göra med papper och penna, typ avgöra tidintervallet mellan två toppar hos en signal. Dessutom kan man göra lite mer avancerade saker som medelvärdesbildning av flera mätningar eller integrera signalamplituden över tiden. Har man en samplad signal är det också lätt att transformera den och göra analyser i frekvensplanet som att studera frekvensspektrumet.

Vad behöver man tänka på då en signal skall samplas? Dels måste man veta vilket frekvensinnehåll som signalen har. Ty för att kunna representera en signal entydigt måste samplingsteoremet vara uppfyllt dvs $f_{sampling}=2*f_{max}$. Detta kan dock åstadkommas även för högfrekventa signaler genom att först lågpassfiltrera signalen. Att sampla med en hög samplingsfrekvens kräver större datorkraft och mer lagringsutrymme. Ett sätt att komma runt detta är att skjuta in nollor på slutet av signalen. Effekten blir att signalen tycks ha större upplösning i frekvensplanet än den egentligen har, se bilaga 1. För att få en bra sampling måste A/D omvandlaren ha tillräcklig upplösning för att man skall kunna särskilja olika amplitudnivåer och därmed även små toppar.

Signaler från kroppen är stokastiska. Stokastiska signaler kan beskrivas mha akf:en. När man räknar fram akfen så brukar man gå via DFT. Akf:en beräknas från en signal x[n] enligt följande. 1. Räkna ut X[k] = DFT{x[n]} 2. Beräkna |X[k]| 3. Akf:en r[n] fås som r[n] = IDFT{|X[k]|}. Tyvärr så brukar det uppstå ”wraparounderror” om vi inte råkat sampla signalen i ett helt antal perioder. Återigen så kan man lösa problemet med att skjuta in ett antal nollor i slutet av signalen. Om antalet nollor är lika stort som signalen så uteblir felet. Ett annat sätt att komma runt ”wrap around” effekten är att vid beräkningen av akf:en använda en anpassad algoritm som endast summerar över signalens längd. r[k] för stora k kommer givetvis inte att bli lika bra då men vi slipper ”wrap around” felet. Spektraltätheten får vi på köpet om vi beräknar akf:en via DFT annars fås den genom att fouriertransformera akf:en. Frekvensspektrumet är framför allt bra när man vill studera olika frekvenskomponenter tex fördelning av högfrekventa resp lågfrekventa komponenter i signalen.

Typiska tillämpningar i tidsplanet.

Att studera ”evoked potentials” (EP) kan vara besvärligt utan någon signalbehandling eftersom signalerna i hjärnan som man vill mäta är har mycket mindre amplitud än tex aktionpotentialer som också förekommer i mätomgivningen. För att kunna registrera EP låter man stimulera samma nerv några hundratal gånger. Sedan medelvärdesbildar man de uppmätta signalerna och EP framträder då tydligare medans bruset som man inte vill mäta dämpas. Ett annat exempel där datorer kan snabba upp ett mätförfarande är i situationer då man vill mäta tiden mellan två toppar. Toppar är relativt lätta att upptäcka med en dator. Exempelvis då ett EKG registreras kan man ta fram tiden mellan två QRS komplex och slå larm om tiden blir för lång eller kort.

Typiska tillämpningar i frekvensplanet

Om man har en väldigt brusig signal kan det i många fall vara enklare att studera egenskaper hos signalen i frekvensplanet. Brus reduceras också kraftigt om man använder en sk ”smoothing” teknik, dvs medelbärdebildar över en större mängd spektrum alternativt mellan närliggande sampel i samma spektrum.

EMG kan med fördel studeras i frekvensplanet. Om vi låter spänna en muskel länge så kommer frekvensinnehållet att flytta sig mot allt lägre frekvenser. Om vi använder en dynamisk spektralanalys kan således muskeltrötthet upptäckas. Andra patologiska typer av signaler visar sig också som förskjutningar eller förvrängningar i frekvensspektrummet. Tex polyfasiska potentialer i EMG har ett frekvensinnehåll som är mycket högre än normalt.

Andra analysmetoder

Kraftfullare datorer har gjort det möjligt att inom rimlig tid lära upp neurala nät att diagnosticera mätreslutat. Som exempel kan nämnas att man med backpropagation algoritmen lärde upp ett nät att klassificera EMG signaler och ett Hopfield nät för att beräkna timeseriesparametrar och moving average med godkänt resultat. Dock fortfarande så finns det inget system som man skulle vilja ersätta en riktig läkare med utan systemen skulle fungerar mer som rådgivande system.

Av Henric Karlsson

Bilaga 1

Ett sätt att öka upplösningen på signalen är att skjuta in nollor efter sista samplet. vilket ses av följande beräkningar.

Definitionen av Fouriertransformen

$$X[\theta] = \sum_{n=-\infty}^{-\infty} x[n]e^{-j2\pi\theta}$$

Och av en L-punkters DFT, N är längden på x(n)

$$DFT\{x[n]\} = X_L[k] = \sum_{n=0}^{N-1} x[n]e^{-j\left(\frac{2\pi k}{L}\right)n}$$

Antag sekvensen

$$h_L[n] = \begin{cases} h_N[n] & n = 0, 1, \ldots, N - 1 \\ 0 & n = N, N+1, \ldots, L - 1 \end{cases}$$

Då får vi att

$$H_L[k] = \sum_{n=0}^{L-1} h_L[n]e^{-j\frac{2\pi k}{L}n} = \sum_{n=0}^{N-1} h_N[n]e^{-j\frac{2\pi k}{L}n} = \sum_{-\infty}^{\infty} h[n]e^{-j\frac{2\pi k}{L}n} =$$

$$H\left[\frac{k}{L}\right]$$

Medans motsvarande för

$$H_N[k] = \sum_{n=0}^{N-1} h_N[n]e^{-j\frac{2\pi k}{N}n} = H\left[\frac{k}{N}\right]$$

Dvs vår signal som var utfylld med nollor fick en upplösning på k/L medans den ursprungliga signalen hade en upplösning på k/N och L>N.