

Klassificering av hyperkinesi i Parkinsonsjuka

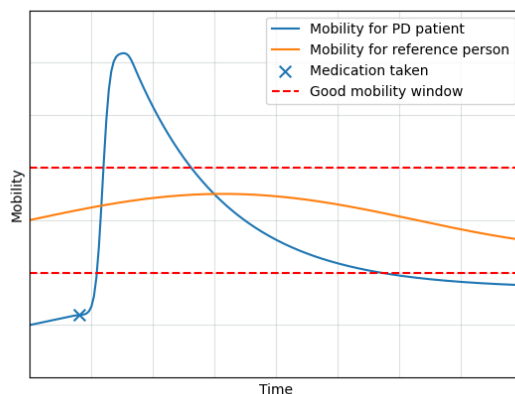
Gustaf von Grothusen

December 2022

I mitt exjobb, "Classification of hyperkinesia in Parkinson patients", föreslår jag en modell för att klassificera hyperkinesi, som är ett vanligt Parkinsonsymptom. Modellen använder accelerometerdata som inhämtats med en smartphone som input och förutspår vilken grad av hyperkinesi bäraren har. För att förklara termen hyperkinesi behövs lite bakgrund: Parkinsons sjukdom, PD förkortat, är en neurologisk sjukdom som är degenerativ och har inverkan på vårt motorsystem. Den tidigare lundastudenten Arvid Carlsson fick Nobelpriset i medicin eller fysiologi för att föreslå att det var brist på dopamin som orsakade sjukdomen och idag vet man att det är neuroner i den del av hjärnan som kallas basalganglierna som normalt sett står för dopaminproduktionen, och det är just dessa som blir nedsatta under sjukdomsförloppet. De dör stegvist, vilket gör att man till en början inte märker av sjukdomen. Först när tillräckligt många av dessa celler inte fyller sin funktion, och man får en tillräckligt låg koncentration dopamin i hjärnan, börjar symptomen yttra sig. Dessa symptom är ofta så kallade dyskinesier, som innebär att kroppens motorfunktioner fungerar sämre än de ska.

Den vanligaste behandlingen för patienter med diagnosen är att medicinera med en föregångare, eller precursor till dopamin, Levodopa. Denna kur ökar halterna dopamin i hjärnan artificiellt, och man återfår stora delar av den motorfunktion man har tappat till följd av sjukdomen. Behandlingen är effektiv och har i regel stor inverkan på de drabbades liv, vilket är en av anledningarna till att Carlsson blev belönad för sitt arbete. Hur som helst så finns det som med alla behandlingar biverkningar. I detta fall är en vanlig biverkning hyperkinesi, överrörlighet. När man tar medicinen får man en topp av dopaminkoncentration, och istället för att vara underrörlig blir man överrörlig. I sin tur innebär detta att man gör oavsiktliga rörelser. Se figur 1.

Ett problem med hyperkinesier är att det är svårt för kliniker att veta vilken grad av hyperkinesier de diagnosticerade har: Ett vanligt intervall för besök är två gånger per år, där patienterna har 30 minuter med sin läkare. Under denna tid gör läkaren en bedömning om patienternas tillstånd, och bestämmer i samråd med patienten huruvida behandlingen ska modifieras. Här behöver läkaren ta ett stort beslut, med stor inverkan på den drabbades



Figur 1: Rörlighetskurva för medicinerad Parkinsonsjuk och referensperson. Det här mönstret repeteras vidare under dagen, och den vanlig dosering är ca var fjärde timme.

liv, men med för lite data för att få en säker uppfattning om den diagnostiserades tillstånd. Många läkare upplever också att patienten anstränger sig mer än vanligt för dölja sina symptom under besökstiden, på samma sätt som många borstar tänderna extra noggrant inför ett tandläkarbesök. Mot denna bakgrund har frågeställningen växt fram: Hade man kunnat utveckla en algoritm som kan avgöra graden av hyperkinesier, för att få mer underlag till att ta dessa viktiga beslut?

I ett försök att tackla detta problem, har Dr. Sotirios Grigoriou och hans team på neurologiska avd. i Lund börjat samla accelerometerdata från patienter med hyperkinesier. Detta har genererat ett dataset med 25 deltagare och 429 insamlade prov, med tillhörande etiketter. Det är denna data som har varit tillgänglig för mig i mitt arbete, och har använts för att träna modeller, som förutspår graden av hyperkinesier. En viktig del av mitt arbete har varit att välja på vilket sätt som datan behandlas innan den åker in i modellerna. Eftersom graden av hyperkinesi inte är enkel att avgöra utifrån att kolla på obehandlad data, behöver den abstraheras till en enklare, mer lättsmält form. Detta steg kallas ofta "feature extraction" (säregenskapsextrahering om man så vill), och i mitt arbete har jag kommit fram till features som är bra på att beskriva hyperkinesi.

Denna manuella feature extraction är ofta utlämnad ur machine learning-problem. Anledningen är att nätverk är tänkta att lära sig en optimal feature extraction automatiskt genom träning. Det som dock krävs för att de ska lära sig bra features är att det finns mycket data, gärna ett par tusen prov, som är relativt rena från brus. Dessa förutsättningar finns helt enkelt inte: vi har 429 prov med i regel mycket brus.

Med manuellt bestämda features, tränades support vector machines och följande resultat erhöles:

träffsäkerhet (accuracy)	noggrannhet (precision)	igenkänning (recall)	f1_score
0.897	0.921	0.827	0.867

Tabell 1: Resultat för den föreslagna modellen för binär klassificering.

ρ	ρ expert A	ρ expert B	MSE	MAE	worst
0.842	0.748	0.830	0.218	0.304	1.449

Tabell 2: Resultat för den föreslagna regressionsmodellen. ρ är korrelationskoefficienten, MSE är medelkvadratfelet and MAE är medelabsolutfelet. Värdet längst till vänster motsvarar korrelationen mot medelvärdet av de två läkarnas bedömningar.

Resultaten modellerna uppvisar är lovande, i synnerhet eftersom bedömningar från läkare ofta är motstridiga:

ρ	MAE
0.790	0.303

Tabell 3: Experterna är till viss del oeniga, och har en korrelation på 0.79. Detta är ungefär samma som min modell har i korellation mot var och en av experterna.

Eftersom den föreslagna regressionsmodellen har ungefär lika bra korrelation med vardera läkare som läkarna har med varandra, så kan man argumentera för att modellen genererar prediktioner i linje med vad som hade kunnat förväntas av en tredje läkare. Förhoppningen med dessa resultat är att belysa möjligheten till den här typen av patientuppföljning, och eventuellt inspirera till fortsatt arbete inom området. Nästa steg är att sätta upp experiment för att påvisa att kvaliteten av prediktionerna, så att tekniken kan införlivas och göra nytta på riktigt.

Gustaf von Grothusen, 2022-12-14