



# Estudi sobre la quantificació del grau de consciència del malalt durant la sedació pal·liativa.

Document:

Treball de final de grau

Autor/Autora:

Karla Font

Director/Directora - Codirector/Codirectora:

Albert Masip – Xavier Marimon

Titulació:

Grau en Enginyeria Electrònica Industrial i Automàtica

Convocatòria:

Juliol, 2023.

TREBALL DE FI D'ESTUDIS



## RESUM

En el camp de la medicina, aquests darrers anys s'ha pogut observar una clara tendència a l'alça, en reduir el patiment i augmentar la tranquil·litat al final de la vida. Tothom en algun moment ha de morir, i que aquest procés sigui indolor s'ha convertit en una prioritat, com s'ha pogut veure amb les cures pal·liatives o l'eutanàsia. En aquest punt entra en joc l'índex bispectral.

En l'actualitat, aquest valor es fa servir en àmbits relacionats amb l'anestèsia, com a complement de les escales observacionals. Però cal destacar que aquest índex proporciona dades objectives, en contraposició a les escales observacionals que són purament subjectives.

En aquest treball es busca analitzar la situació actual del BIS, així com intentar simular i predir aquest índex amb un ordinador, per tal de poder implementar aquesta recerca al mercat. Aquest estudi va lligat a un altre anomenat: «*A new based-model BIS Index study for awareness monitoring during palliative sedation*». Aquest ha sigut realitzat per Carlota Lacasa Vela de la Universitat Internacional de Catalunya (UIC) i en aquests dos estudis s'han establert diferents enfocaments, un des d'una perspectiva més mèdica i en l'altre estudi un enfoc en el camp de l'enginyeria.

Per a dur a terme aquest treball, s'ha fet una àmplia recerca bibliogràfica d'articles científics i treballs anteriors. Un cop realitzada aquesta part, es van haver d'aconseguir les dades necessàries per poder treballar amb identificació de sistemes. Aquestes dades de treball, van ser proporcionades per l'hospital de la Vall d'Hebron. Es va utilitzar el programari Matlab i l'eina d'identificació de sistemes per estimar els paràmetres per tal d'aconseguir el model òptim amb el mínim nombre de canals necessaris.

Els resultats de l'estudi conclouen que podem simular a 2min 35seg vista, l'estat del pacient una vegada s'ha administrat la dosi de fàrmacs pertinent. Per tant, amb aquest codi, es podria veure si la dosi subministrada és l'adequada o, per al contrari, és inferior o superior a la desitjada.

Cal més estudi en aquest camp i portar a la realitat aquests avenços, però és un bon pas per a enfrontar en la problemàtica que existeix en cures pal·liatives, relacionades amb la sobre sedació o sub-sedació. Per tant, en cap cas cal eliminar al 100% les escales observacionals, però sí que hauria de ser una realitat la seva convivència a l'hora de tractar els pacients.

## RESUMEN

En el campo de la medicina, en los últimos años se ha podido observar en auge el objetivo de reducir el sufrimiento y aumentar la calma al final de la vida. Todo el mundo en algún momento morirá, y que este proceso sea indoloro se ha convertido en una prioridad, como por ejemplo en las curas paliativas o la eutanasia. En este punto entra en juego el índice bispectral.

Actualmente, este valor se usa en las áreas relacionadas con la anestesia, como podrían ser las cirugías y como complemento de las escalas observacionales. Pero es importante recalcar que este índice proporciona datos objetivos, todo lo contrario, a las escalas observacionales que son puramente subjetivas.

En este trabajo se busca analizar la situación actual del BIS, así como intentar simular y predecir este índice con un ordenador, con el fin de poder implementar esta investigación en el mercado. Este estudio va relacionado a un altre llamado: «*A new based-model BIS Index study for awareness monitoring during palliative sedation*». Éste ha sido realizado por Carlota Lacasa Vela y en estos dos estudios se han establecido diferentes enfoques, uno desde una perspectiva médica y otro enfocado al campo de ingeniería.

Para llevar a cabo este trabajo, se ha realizado una amplia búsqueda de artículos científicos y trabajos anteriores. Una vez realizada esta parte inicial, se necesitaron los datos para poder trabajar con los diferentes modelos y el hospital de la Vall d'Hebron fue quien los proporcionó. A partir de ese punto, se fueron programando los modelos que querían estudiarse mediante Matlab, hasta poder extraer las conclusiones.

Los resultados del estudio concluyen que podemos simular a 2min 35seg vista, el estado del paciente una vez se ha administrado la dosis de fármacos pertinente. Por lo tanto, con este código, se podría ver si la dosis suministrada es la adecuada o, por el contrario, es inferior o superior a la deseada.

Es necesario más estudio en este campo y llevar a la realidad estos avances, pero es un buen paso para enfrentar la problemática que existe en cuidados paliativos, relacionados con la sobre sedación o subsedación. Por tanto, en ningún caso hay que eliminar al 100% las escalas observacionales, pero sí debería ser una realidad su convivencia a la hora de tratar a los pacientes.

## ABSTRACT

In the field of medicine, in recent years, there has been a clear upward trend in reducing the suffering and increasing the calm at the end of life. Everyone has to die at some point, and ensuring a painless process has become a priority, as seen in palliative care area or euthanasia. This is where the Bispectral Index (BIS) comes into play.

Currently, BIS values are used in anaesthesia-related settings as a complement to observational scales. However, it is important to note that this index provides objective data, in contrast to observational scales, which are purely subjective.

This study aims to analyse the current status of BIS and attempt to simulate and predict this index using a computer with the aim to implement this study in the market. This research is closely related to another study titled "A new based-model BIS Index study for awareness monitoring during palliative sedation" written by Carlota Lacasa Vela. These two studies have established different perspectives, one from a medical standpoint and the other focused on the field of engineering.

To carry out this work, extensive research on scientific articles and previous studies was conducted. Once this part was completed, the necessary data had to be obtained to work on the different models, which was provided by Vall d'Hebron Hospital. From there, the models were programmed using Matlab, aiming to draw conclusions.

The study's results conclude that we can simulate, with a 2 minute and 35 second advance, the patient's state after administering the relevant drug dose. Therefore, with this code, it would be possible to determine if the administered dose is adequate or, conversely, too low, or too high.

Further research is needed in this field to bring these advancements into reality. However, it is a positive step towards addressing the issues related to oversedation or undersedation in palliative care. It is important to note that observational scales should not be completely eliminated but rather coexist with these advancements in patient treatment.



## Taula de continguts

<b>RESUM</b> .....	<b>1</b>
<b>RESUMEN</b> .....	<b>2</b>
<b>ABSTRACT</b> .....	<b>3</b>
<b>TAULA DE CONTINGUTS</b> .....	<b>4</b>
<b>LLISTAT DE TAULES</b> .....	<b>7</b>
<b>LLISTAT DE FIGURES</b> .....	<b>8</b>
<b>LLISTAT D'ABREVIACIONS/GLOSSARI</b> .....	<b>10</b>
<b>OBJECTE</b> .....	<b>9</b>
<b>ABAST</b> .....	<b>10</b>
<b>REQUERIMENTS</b> .....	<b>11</b>
<b>JUSTIFICACIÓ:</b> .....	<b>12</b>
<b>PLA DE TREBALL INICIAL</b> .....	<b>13</b>
<b>ANTECEDENTS</b> .....	<b>14</b>
<b>ESTAT DE L'ART</b> .....	<b>15</b>
1.1    QUINES DADES ES TRACTEN? COM S'ACONSEGUEIXEN? .....	15
1.2    MODELS LINEALS .....	17
1.3    MODELS NO LINEALS.....	17
<b>MARC TEÒRIC DEL TREBALL</b> .....	<b>18</b>
2.1    BISPECTRAL INDEX™ (BIS™) MONITORING SYSTEM.....	18
2.2    ADQUISICIÓ DE DADES .....	21
2.2.1.1    Procés d'obtenció de dades així com dels elèctrodes .....	21
2.2.1.2    3D.....	21
2.2.1.3    Electrocompatibilitat .....	23
2.3    IDENTIFICACIÓ DE SISTEMES .....	24
2.3.1    Models lineals .....	24
2.3.1.1    OE .....	24
2.3.1.2    ARX .....	26
2.3.2    Models no lineals .....	26
2.3.2.1    NNARX.....	27
2.3.2.2    NNOE.....	29
<b>ANÀLISI DE METODOLOGIES CANDIDATES</b> .....	<b>30</b>
<b>METODOLOGIA MODELS LINEALS</b> .....	<b>31</b>
4.1    MODEL OE D'1 ENTRADA.....	31
4.2    MODEL OE 2 ENTRADES.....	35
4.3    MÍNIM CONJUNT DE DADES .....	36
4.4    MODEL ARX D'1 ENTRADA.....	38
4.5    MODEL ARX 2 ENTRADES.....	39
<b>METODOLOGIA MODELS NO LINEALS</b> .....	<b>40</b>
5.1    NNOE.....	40
5.2    NNARX.....	42
<b>DESENVOLUPAMENT DE LA SOLUCIÓ</b> .....	<b>44</b>

<b>PLA DE TREBALL FINAL .....</b>	<b>45</b>
<b>IMPLICACIONS SOCIALS.....</b>	<b>46</b>
<b>FUTURA IMPLEMENTACIÓ .....</b>	<b>46</b>
<b>BIBLIOGRAFIA CONSULTADA.....</b>	<b>47</b>
<b>ANNEXOS .....</b>	<b>51</b>
10.1 CODI OE EMG .....	51
10.2 CODI OE EEG.....	60
10.3 CODI MÍNIM CONJUNT DE DADES .....	68
10.4 CODI NNOE DADES EMG.....	72
10.5 CODI NNARX DADES EMG .....	74
10.6 TAULA D'ELECTROCOMPATIBILITAT .....	76
10.1 GRÀFICS .....	79
10.1.1 <i>BIS Original</i> .....	79
10.1.2 <i>BIS vs BIS Filtrat</i> .....	79
10.1.3 <i>EMG Original</i> .....	80
10.1.4 <i>EMG vs EM G Filtrat</i> .....	80
10.1.5 <i>EEG Original</i> .....	81
10.1.6 <i>4 canals d'EEG</i> .....	81
10.1.7 <i>EEG Mig dels 4 canals</i> .....	82
10.1.8 <i>EEG vs EEG Filtrat</i> .....	82
10.1.9 <i>EMG + BIS + EEG</i> .....	83
10.1.10 <i>Correlació normalitzada entre EMG i BIS:</i> .....	83
10.1.11 <i>Correlació normalitzada entre EEG i BIS:</i> .....	84
10.1.12 <i>Dades entrenament vs validació senyal EMG</i> .....	84
10.1.13 <i>Dades entrenament vs validació senyal EEG</i> .....	85
10.1.14 <i>Resposta impulsional del senyal EMG</i> .....	85
10.1.15 <i>Índex de correlació senyal EEG</i> .....	86
10.1.16 <i>Resposta a un graó senyal EMG</i> .....	86
10.1.17 <i>Resposta a un graó senyal EEG</i> .....	87
10.1.18 <i>OE [120] [130] [140] [150] senyal EMG</i> .....	87
10.1.19 <i>OE [120] [130] [140] [150] senyal EEG</i> .....	88
10.1.20 <i>OE [120] [130] [140] [150] 2 senyals d'entrada</i> .....	88
10.1.21 <i>OE [220] [230] [240] [250] senyal EMG</i> .....	89
10.1.22 <i>OE [220] [230] [240] [250] senyal EEG</i> .....	89
10.1.23 <i>OE [220] [230] [240] [250] 2 senyals d'entrada</i> .....	90
10.1.24 <i>OE [330] [340] [350] senyal EMG</i> .....	90
10.1.25 <i>OE [330] [340] [350] senyal EEG</i> .....	91
10.1.26 <i>OE [330] [340] [350] 2 senyals d'entrada</i> .....	91
10.1.27 <i>OE [440] [450] senyal EMG</i> .....	92
10.1.28 <i>OE [440] [450] senyal EEG</i> .....	92
10.1.29 <i>OE [440] [450] 2 senyals d'entrada</i> .....	93
10.1.30 <i>OE [550] [560] [570] senyal EMG</i> .....	93
10.1.31 <i>OE [550] [560] [570] senyal EEG</i> .....	94
10.1.32 <i>OE [550] [560] [570] 2 senyals d'entrada</i> .....	94
10.1.33 <i>OE [660] [670] [770] senyal EMG</i> .....	95
10.1.34 <i>OE [660] [670] [770] senyal EEG</i> .....	95
10.1.35 <i>OE [660] [670] [770] 2 senyals d'entrada</i> .....	96
10.1.36 <i>10% de dades utilitzat</i> .....	97
10.1.37 <i>20% de dades utilitzat</i> .....	98
10.1.38 <i>30% de dades utilitzat</i> .....	99
10.1.39 <i>40% de dades utilitzat</i> .....	100
10.1.40 <i>50% de dades utilitzat</i> .....	101

10.1.41	60% de dades utilitzat .....	102
10.1.42	70% de dades utilitzat .....	103
10.1.43	80% de dades utilitzat .....	104
10.1.44	90% de dades utilitzat .....	105
10.1.45	100% de dades utilitzat .....	106
10.1.46	Variació de l'MSE en funció del % de dades utilitzades. ....	107
10.1.47	10% inicial de dades. ....	107
10.1.48	10% final de dades. ....	108
10.1.49	Model oe de l'1% de dades utilitzades. ....	108
10.1.50	Model oe del 10% de dades utilitzades. ....	109
10.1.51	Model oe del 100% de dades utilitzades. ....	109
10.1.52	Error de l'1% de dades utilitzades. ....	110
10.1.53	Error del 10% de dades utilitzades. ....	110
10.1.54	Error del 100% de dades utilitzades. ....	111
10.1.55	Predicció a 1 pas. ....	111
10.1.56	Predicció a 10 passos. ....	112
10.1.57	Predicció a 25 passos. ....	112
10.1.58	Predicció a 50 passos. ....	113
10.1.59	Predicció a 100 passos. ....	113



## Llistat de taules

<b>Taula 1.</b> Formes d'ona de l'EEG .....	16
<b>Taula 2.</b> Valors BIS mostrats i la seva descripció.....	19
<b>Taula 3.</b> Valors de l'escala RSS vs BIS. ....	20
<b>Taula 4.</b> Valors de l'escala RASS vs BIS .....	20
<b>Taula 5.</b> Resultats MSE i FPE de models OE d'una entrada.....	34
<b>Taula 6.</b> Resultats MSE i FPE de models OE de dues entrades. ....	35
<b>Taula 7.</b> Resultats de l'MSE i FPE amb l'ordre definit. ....	39
<b>Taula 8.</b> Resultats de l'MSE i FPE amb l'ordre definit. ....	39
<b>Taula 9.</b> Resultats de l'MSE i FPE amb l'ordre definit. ....	39

## Llistat de figures

<b>Fig. 1.</b> Posicionament dels elèctrodes segons EEG 10-20. Imatge extreta de Bitbrain.....	15
<b>Fig. 2.</b> Posicionament dels elèctrodes segons EEG 10-20. Imatge extreta de Bitbrain.....	16
<b>Fig. 3.</b> Components del sistema de monitorització completa BIS. Imatge extreta de Medtronic ....	18
<b>Fig. 4.</b> Retall de la pantalla principal del monitor BIS. Imatge extreta del manual .....	18
<b>Fig. 5.</b> Disseny de la diadema amb la posició dels sensors. Vista frontal. ....	21
<b>Fig. 6.</b> Disseny de la diadema amb la posició dels sensors. ....	22
<b>Fig. 7.</b> Disseny de la diadema amb les pistes dels sensors ressaltades. ....	22
<b>Fig. 8.</b> Senyal EEG sense filtre. ....	23
<b>Fig. 9.</b> Senyal EMG sense filtre. ....	23
<b>Fig. 10.</b> Arxiu de codi d'impedància dels sensors. ....	23
<b>Fig. 11.</b> Estructura d'un model OE. ....	24
<b>Fig. 12.</b> Anàlisi de correlació sense cap mostra de retard.....	25
<b>Fig. 13.</b> Estructura d'un model ARX. ....	26
<b>Fig. 14.</b> Xarxes monocapes. ....	27
<b>Fig. 15.</b> Xarxes multicapa. ....	27
<b>Fig. 16.</b> Xarxes no recurrents. ....	27
<b>Fig. 17.</b> Xarxes recurrents. ....	27
<b>Fig. 18.</b> Diagrama de l'anàlisi de metodologies candidates. ....	30
<b>Fig. 19.</b> Diagrama del model lineal OE amb 1 entrada.....	31
<b>Fig. 20.</b> Senyal EMG (entrada). ....	31
<b>Fig. 21.</b> Senyal EEG (entrada). ....	31
<b>Fig. 22.</b> Senyal BIS (sortida).....	31
<b>Fig. 23.</b> EMG vs EMG Filtrat. ....	32
<b>Fig. 24.</b> EEG vs EEG Filtrat. ....	32
<b>Fig. 25.</b> BIS vs BIS Filtrat.....	32
<b>Fig. 26.</b> Correlació entre EMG i BIS. ....	32
<b>Fig. 27.</b> Correlació entre EEG i BIS. ....	32
<b>Fig. 28.</b> Senyal EMG i BIS. ....	33
<b>Fig. 29.</b> Senyal EEG i BIS. ....	33
<b>Fig. 30.</b> Resposta impulsional estimada del senyal EMG.....	33
<b>Fig. 31.</b> Resposta impulsional estimada del senyal EEG. ....	33
<b>Fig. 32.</b> Resposta a un graó senyal EMG.....	34
<b>Fig. 33.</b> Resposta a un graó senyal EEG. ....	34
<b>Fig. 34.</b> Diagrama del model OE amb 2 entrades. ....	35
<b>Fig. 35.</b> 10%* de dades utilitzades d'EMG. ....	36
<b>Fig. 36.</b> Comparativa entre les dades de validació i el model escollit. ....	36
<b>Fig. 37.</b> 100%* de dades utilitzades d'EMG. ....	36
<b>Fig. 38.</b> Comparativa entre les dades de validació i el model escollit. ....	36
<b>Fig. 39.</b> Variació de l'mse en funció del % de dades utilitzades.....	37
<b>Fig. 40.</b> 10% inicial de dades. ....	37
<b>Fig. 41.</b> 10% final de dades.....	37
<b>Fig. 42.</b> Model oe de l'1% de dades utilitzades. ....	38
<b>Fig. 43.</b> Model oe del 10% de dades utilitzades.....	38
<b>Fig. 44.</b> Model oe del 100% de dades utilitzades.....	38
<b>Fig. 45.</b> Error de l'1% de dades utilitzades.....	38
<b>Fig. 46.</b> Error del 10% de dades utilitzades. ....	38
<b>Fig. 47.</b> Error del 100% de dades utilitzades. ....	38
<b>Fig. 48.</b> Predicció a un horitzó de 60 passos vs el de 120. Dades EMG.....	39
<b>Fig. 49.</b> Predicció a un horitzó de 60 passos vs el de 120. Dades EEG.....	39
<b>Fig. 50.</b> Resultats de la predicció de la funció 'nvalid'.....	40
<b>Fig. 51.</b> Funció d'autocorrelació de la predicció de l'error. ....	40
<b>Fig. 52.</b> Histograma dels errors de predicció. ....	41
<b>Fig. 53.</b> Predicció a 1 pas. ....	41



<b>Fig. 54.</b> Predicció a 10 passos. ....	41
<b>Fig. 55.</b> Predicció a 25 passos. ....	41
<b>Fig. 56.</b> Predicció a 50 passos. ....	41
<b>Fig. 57.</b> Predicció a 100 passos. ....	41
<b>Fig. 58.</b> Estructures de les neurones al model no lineal NNARX. ....	42
<b>Fig. 59.</b> A: Sortida real vs sortida predita. ....	42
<b>Fig. 60.</b> Funció d'autocorrelació a l'estructura [HHH, L--] amb un ordre [110]. ....	42
<b>Fig. 61.</b> Diferència al model NNARX amb un horitzó de predicció d'1 i 120. ....	43
<b>Fig. 62.</b> Pla de treball final. ....	45
<b>Fig. 63.</b> Pla de treball inicial. ....	45

## Llistat d'abreviacions/Glossari

BIS: Bispectral Index Scale

OE: Output Error

ARX: AutoRegressive eXogeneous variable

RRS: Ramsay Sedation Scale

RASS: Richmond Agitation Sedation Scale

PCS: Patient Comfort Score

OS: Observational Scales

EEG: Electroencefalograma

EMG: Electromiograma

NNOE: Neural Network Output Error model

NNARX: Neural Network AutoRegressive eXogeneous model

HMI: Human Machine Interface

PIC: Patient Interface Cable

UCI: Unitat de Cures Intensives

FFT: Fast Fourier Transform

MSE: Mean Square Error

FPE: Final Prediction Error

UDS: Unidades

HGC: Hospital General de Catalunya

## Objecte

Una afirmació en la qual gairebé tothom coincideix, és que es desitja morir de manera plàcida i indolora. Però, si estem envers un cas sense cura en el que el pacient només pateix, ha de ser possible morir sense agonia, sense patiment i sense fer palès del malestar als familiars.

En aquest punt entren les cures pal·liatives, entre altres teràpies. Aquestes ajuden a afeblir el dolor causat per algunes malalties que no tenen cura i que van en detriment del pacient, fins que aquest acaba morint. Però les decisions que tenen a veure amb l'administració de fàrmacs, horaris i dosis, avui en dia es fan de manera observacional i subjectiva. Sense assegurar o aproximar de manera empírica si aquella persona està patint per molt sedada que estigui.

En aquest treball, inicialment es tractarà quina és la situació actual del BIS. Gràcies a una exhaustiva recopilació d'articles i reunions amb infermeres i una doctora, podem conèixer com evoluciona el BIS dins l'àmbit mèdic.

L'objectiu principal és dissenyar un programa que simuli i predigui el BIS, per tal de poder-ho implementar en un futur. En el transcurs d'aquest, s'aniran analitzant diferents identificacions de sistemes dinàmics com l'OE, l'ARX, l'NNOE i l'NNARX i finalment s'escollirà el que millor s'adeqüi als resultats reals i desitjats.



## Abast

El treball consta de diferents fases.

- Recerca exhaustiva de documents actuals sobre el BIS i les cures pal·liatives. Amb la seva corresponent publicació a una revista mèdica.
- Recollida de dades reals de pacients a hospitals.
- Programació i simulació de sistemes dinàmics.
- Verificar, negar o modificar la hipòtesi inicial.
- Es realitzarà una altra publicació científica amb tota la feina feta durant els mesos de l'estudi posteriorment a la seva entrega.
- Prototip per a modificar en un futur dels sensors utilitzats pels hospitals.

En aquest treball no es farà:

- Un software que predigui el nivell de consciència
- Un únic model de simulació.
- El disseny complet/estudi d'un sensor cranial.
- Implementació al mercat
- Disseny d'un sensor funcional



## Requeriments

Les especificacions bàsiques i restriccions que es consideren en aquest treball són:

- Ús de llenguatge formal i professional.
- Els temes mèdics tractats han d'estar autoritzats per les infermeres/doctores consultades.
- El programari utilitzat serà Matlab i SolidWorks.

## Justificació:

L'estudi d'aquest projecte ve propiciat per la necessitat d'acabar, o com a mínim, reduir plausiblement amb l'agonia dels malalts.

Les decisions preses en aquest camp cal que siguin objectives i eficaces, no és correcte que el patiment d'una persona que es troba al llit d'un hospital, estigui decidit pel criteri d'un infermer o infermera. Cal recalcar que no es vol menysprear el criteri professional ni les decisions que prenen, però és cert que no poden decidir objectivament si una persona pateix o no, pel fet d'observar-la.


Avui en dia, en aquestes pràctiques s'utilitzen escales observacionals subjectives com l'RRS, l'RASS o PCS, però s'ha vist en certs estudis que el nivell de sedació que aquestes prediuen, no corresponen a l'índex bispectral, un valor objectiu.

Els resultats acostumen a concloure que, amb les mateixes dades, el nivell de sedació amb les escales observacionals, resulten ser elevats (alt nivell de sedació), mentre que el BIS, acostuma a donar xifres més baixes en sedació (baix nivell de sedació). Es poden afirmar resultats molt dispars entre les OS i el BIS per a un mateix pacient.

La resolució d'aquest treball pot ajudar a predir aquests nivells de sedació de manera objectiva i sense la necessitat de tenir aparells d'última generació, ja que la simulació i predicció s'haurà fet amb un simple ordinador. Per tant, saber el nivell de sedació d'un pacient podrà estar a l'abast de molts més pacients, ja no caldrà decidir a qui se li posa i a qui no, perquè la inversió per a poder fer servir l'aparell serà molt menor a la marca pionera del mercat.

## PLA DE TREBALL INICIAL

### DIAGRAMA DE GANTT



- Recerca: Lectura d'articles relacionats amb el tema tractat
- Recol·lecció de dades: Vegades que s'ha anat a l'hospital a buscar dades
- Parlar amb hospitals: Vegades que s'ha tractat amb personal de l'hospital, tant per recerca, com per dades.
- Redacció de l'article: Recopilar tota la informació en un document pautat per una revista científica.
- Modelat de sensor: Presa de mesures i prototipatge del sensor cranial.
- Redacció de la memòria: Aglutinar tota la informació del treball de manera ordenada.
- Tractament de dades: Adequar les dades per poder començar a experimentar amb els diferents sistemes.
- Assaigs de sistemes: Experimentació.

Com es pot veure en el diagrama de Gantt quasi totes les activitats van relacionades entre si, si no s'acaben unes, no poden començar les altres. A més es poden veure dues activitats crítiques com serien el modelatge del sensor i la redacció de l'article. Fins que aquestes no han finalitzat no es poden dur a terme les següents.

## ANTECEDENTS

Alguns dels treballs pretèrits a aquest serien:

- Garbiñe De Miguel Ansó. «*Desarrollo de un sistema de gestor de alarmas basado en cardiogramas (CTG) para la asistencia al parto*» [en línia]. Treball de final de grau, UPC, Escola Superior d'Enginyeries Industrial, Aeroespacial i Audiovisual de Terrassa, 2016. [Consulta: 5 de maig 2023]. Disponible a: <https://upcommons.upc.edu/handle/2117/107496>
- José Manuel González Cava. «*Monitorización de la información del electroencefalograma en el proceso anestésico*» [en línia]. Treball de final de grau, Universitat de la Laguna, Escola Superior d'enginyeria i tecnologia, 2014. [Consulta: 5 de maig 2023]. Disponible a: [https://drive.google.com/drive/u/0/folders/1IZTmH\\_2KUoZj-RLPXMwfBknQy1q2W08p](https://drive.google.com/drive/u/0/folders/1IZTmH_2KUoZj-RLPXMwfBknQy1q2W08p)
- Joana Collet Fàbregas. «*Machine learning prediction of burst suppression under general anesthesia*» [en línia]. Treball de final de grau, Universitat de Barcelona, Facultat de Bioenginyeria, 2022. [Consulta: 5 de maig 2023]. Disponible a: [https://drive.google.com/drive/u/0/folders/1IZTmH\\_2KUoZj-RLPXMwfBknQy1q2W08p](https://drive.google.com/drive/u/0/folders/1IZTmH_2KUoZj-RLPXMwfBknQy1q2W08p)
- Ana de la Torre García. «*Proyecto de implementación de un sistema de bajo coste y código abierto para estimación del nivel de consciencia*» [en línia]. Treball de final de grau, Universitat Politècnica de València, Facultat d'enginyeria biomèdica, 2021. [Consulta: 5 de maig 2023]. Disponible a: [https://drive.google.com/drive/u/0/folders/1IZTmH\\_2KUoZj-RLPXMwfBknQy1q2W08p](https://drive.google.com/drive/u/0/folders/1IZTmH_2KUoZj-RLPXMwfBknQy1q2W08p)
- Andrea Navarro i López. «*Estudi sobre les xarxes neuronals artificials*» [en línia]. Treball de final de grau, Universitat de Barcelona, Facultat de Matemàtiques, 2016. [Consulta: 5 de maig 2023]. Disponible a: <https://diposit.ub.edu/dspace/bitstream/2445/98246/3/memoria.pdf>
- Ferran Noguera Vall. «*Compresió de Xarxes Neuronals artificials*» [en línia]. Treball de final de grau, UPC, Facultat d'Informàtica de Barcelona, 2019. [Consulta: 5 de maig 2023]. Disponible a: <https://upcommons.upc.edu/bitstream/handle/2117/133053/136885.pdf?sequence=1&isAllowed=y>
- Carlos Arturo Alva Coras. «*Procesamiento de señales de electromiografía superficial para la detección de movimiento de dos dedos de la mano*» [en línia]. Treball de final de grau, Universitat Ricardo Palma, Facultat d'Enginyeria Electrònica, 2012. [Consulta: 5 de maig 2023]. Disponible a: [https://repositorio.urp.edu.pe/bitstream/handle/20.500.14138/416/Alva\\_ca.pdf?sequence=1&isAllowed=y](https://repositorio.urp.edu.pe/bitstream/handle/20.500.14138/416/Alva_ca.pdf?sequence=1&isAllowed=y)

A més cal destacar el treball paral·lel fet per la meua companya:

- Carlota Lacasa Vela. «*A new based-model BIS Index study for awareness monitoring during palliative sedation*» [en línia]. Treball de final de grau, Universitat Internacional de Catalunya, Facultat de Medicina i Ciències de la Salut, 2023.

## ESTAT DE L'ART

Hi ha una branca dins la medicina anomenada medicina pal·liativa que va sorgir entorn del 1967 a Londres, de la mà de Dame Cicely Saunders, però no va ser reconeguda per l'organització mundial de la Salut fins al 1980. A aquesta pràctica la van anomenar cures pal·liatives i fins al 2002 no es va acabar de definir què englobava [3][4].

Bàsicament, l'objectiu cercat és millorar la qualitat de vida d'aquells pacients que pateixen una malaltia crítica o un estat vital, que ja no es pot revocar, o sigui, ajuden a disminuir el nivell de dolor que poden patir aquestes persones quan la seva situació no té cura. Cal mencionar que no només és una ajuda pels pacients, sinó també per als familiars i gent propera al malalt a pair la situació.

Les cures pal·liatives no se centren només en l'assistència física dels malalts, sinó també en els aspectes psicològics i emocionals, tant a l'hospital com a les llars. A conseqüència d'aquesta assistència, el monitoratge dels pacients ha augmentat i ha passat a tenir un paper més rellevant.

Gràcies a aquest fet s'han desenvolupat diferents aparells per tal de controlar de manera més efectiva i veloç l'estat dels pacients, així com de tractar les dades i emmagatzemar-les. Amb aquestes dades i el seu processat, s'aconsegueix una visió objectiva de l'estat del pacient i no com fins aleshores que només existia l'opinió subjectiva i professional del personal hospitalari.

### 1.1 Quines dades es tracten? Com s'aconsegueixen?

Les dades que es necessiten i tracten són principalment l'electroencefalograma i l'electromiograma.

L'electroencefalograma va néixer el 1929 de la mà d'un neuròleg i psiquiatre alemany de nom Hans Berger [5][6]. *Electroencefalograma* es defineix com a "L'enregistrament gràfic de les variacions elèctriques de les cèl·lules cerebrals obtingut mitjançant un electroencefalògraf." (diec2, s.f., definició 1) [7] *Electroencefalògraf* es refereix a "l'aparell per a mesurar i enregistrar les formes d'ona relatives al funcionament del cervell." (diec2, s.f., definició 1) [7].

Es basa en la detecció, mesura i enregistrament de l'activitat cerebral sense fer servir pràctiques mèdiques invasives [6][8]. Bàsicament, registra les fluctuacions elèctriques del cervell mitjançant uns elèctrodes, aquests polsos elèctrics són deguts a la comunicació entre neurones, ja que es genera una petita activitat elèctrica i, a més, es produeixen canvis bioquímics entre les cèl·lules [9].

Per a poder realitzar un electroencefalograma és important situar de manera correcta els elèctrodes en les regions d'interès. Aquestes es van definir a un comitè l'any 1947, perquè va crear un estàndard per al registre de senyals amb EEG.

D'aquí va sorgir l'estàndard EEG 10-20 i resulten necessaris 21 elèctrodes com a mínim, però segons el percentatge que es vulgui deixar entre els sensors el nombre d'elèctrodes necessaris augmenta [10]. Si l'espai entre elèctrodes es vol reduir a un 10% en comptes d'un 20%, s'obté el posicionament 10-10 amb 81 sensors i l'última distribució que es pot aplicar és la 10-5, que necessita 320 elèctrodes. És el que es coneix com a EEG d'alta resolució.


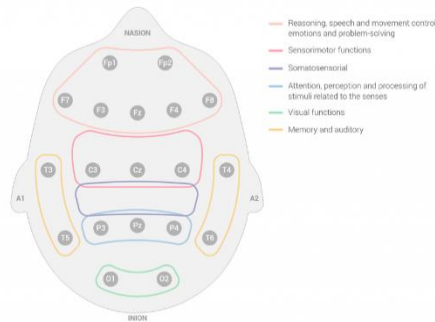


Fig. 1. Posicionament dels elèctrodes segons EEG 10-20. Imatge extreta de Bitbrain [10].

El cervell es divideix principalment en 5 lòbuls: El frontopolar (Fp), frontal (F), central (C), temporal (T), parietal (P) i occipital (O) i cadascun d'ells té unes funcions específiques.

1. **Frontal:** S'encarrega del processament de les funcions cognitives. Per exemple: el Raonament, la Coordinació, les Emocions, el Control de la parla, l'Empatia, l'Execució de tasques, la Resolució de problemes...
2. **Central:** Va relacionada amb les emocions i l'àmbit sensoriomotor
3. **Parietal:** Percep els estímuls sensorials. Així com: la Pressió, la Temperatura, el Dolor...
4. **Occipital:** Aquest lòbul està dividit en àrees. La primera d'elles és la interpretació d'imatges. Seguidament ve la visió i el reconeixement espacial i per última la diferenciació de moviments i colors.
5. **Temporal:** Realitza els aspectes relacionats amb la percepció i reconeixement de l'audició, a més de la memòria.



**Fig. 2.** Posicionament dels elèctrodes segons EEG 10-20. Imatge extreta de Bitbrain [10].

El funcionament de l'electroencefalograma és el següent:

Els elèctrodes es posicionen al cuir cabellut i d'acord al posicionament normalitzat descrit en l'apartat anterior. El senyal analògic es registra amb un amplificador de biopotencials i és convertit a un senyal digital mitjançant un convertidor analògic digital. Abans d'amplificar el senyal, cal filtrar el soroll de la xarxa elèctrica i les freqüències fora de la banda d'interès sota estudi.

Les ones de l'EEG depenen del nivell de consciència i, és molt important tenir en compte que l'únic moment en el qual no es troba senyal és quan el pacient està mort, durant tot el període de sedació per molt profunda que aquesta sigui, continua havent-hi senyal.

Forma d'ona	Descripció	Freqüència	Visualització
Delta ( $\delta$ )	Son profund	0,5-4Hz	
Theta ( $\theta$ )	Relaxació profunda/Son lleuger	4-7Hz	
Alpha ( $\alpha$ )	Despert i relaxat	8-12Hz	
Beta ( $\beta$ )	Despert i totalment conscient	13-30Hz	

**Taula 1.** Formes d'ona de l'EEG [11].

L'electromiografia (EMG) va començar a prendre importància a mitjans del segle XVII, de la mà de William Gilbert i Francesco Redi. *Electromiograma* és el “Registre gràfic de la contracció d'un múscul com a resultat de la pràctica de l'electromiografia.” (diccionari.cat, s.f., definició 1) [7]. *Electromiografia* és el “Mètode utilitzat per a enregistrar els canvis de potencial elèctric que es produeixen en un múscul aïllat o en un grup muscular quan es contreu espontàniament o per inducció amb estímuls generalment elèctrics.” (diccionari.cat, s.f., definició 1) [7].

L'electromiografia es basa a mesurar, registrar i analitzar d'un múscul o d'un nervi la seva activitat bioelèctrica. Es pot extreure un valor de voltatge gràcies a la reacció dels músculs envers els senyals elèctrics que els nervis els hi fan arribar.

Per tal de realitzar una prova EMG cal executar certs passos, tal com succeeix amb l'EEG.

Primer de tot cal que la persona s'assegui o s'estiri de manera relaxada, en aquest punt l'infermer/a netejarà la zona del múscul on es farà la prova. Seguidament, mitjançant una petita agulla que realment és un sensor i es mesura l'amplitud del senyal amb el múscul en repòs. Una vegada duta a terme la mesura, es demana contraure de manera lenta el múscul. Quan es finalitza es comprova que el senyal obtingut és el corresponent sense errates i es procedeix a retirar l'elèctrode.

## 1.2 Models Lineals

Aquest tipus de models són àmpliament utilitzats a l'anàlisi de sistemes, ja que permeten tenir una comprensió més profunda del comportament del model estudiat, així com el disseny i la implementació de nous processos i tècniques avançades. En molts casos, com el d'aquest estudi, s'acostumen a representar en primera instància models no lineals i si aquest no té un comportament satisfactori amb les hipòtesis plantejades, es busca un model no lineal.

Quan es vol representar el comportament d'un sistema cal conèixer els models matemàtics preestablerts, amb motiu d'analitzar-los i comparar-los per representar de manera satisfactòria, els resultats finals desitjats. En el cas d'aquest treball s'analitzaran dos models paramètrics, l'OE i l'ARX, que són aquells capaços de descriure el comportament del model amb un nombre finit de paràmetres.

## 1.3 Models No Lineals

Un dels primers models de xarxes neuronals que va aparèixer, fou estudiat per Warren S. McCulloch i Walter Pitts l'any 1943 [12][13]. Aquest es basa en l'explicació del sistema nerviós humà i es nodreix principalment del coneixement de l'època envers les neurones i les seves connexions, cal destacar que no se centren en els aspectes fisiològics de les neurones sinó en les seves capacitats computacionals.

Les neurones tenen cinc punts clau que McCulloch i Pitts adapten per al seu model de xarxa neuronal. S'ha de tenir en compte que l'activitat neuronal té un procés de “tot o res”, per tant, el model ha de ser binari. Perquè una neurona s'activi, un nombre específic d'enllaços entre neurones ha de rebre un estímulo en un cert període de temps, d'aquesta manera, en el model, cada neurona pot rebre diverses entrades d'enllaços entre neurones que tinguin la mateixa rellevància o el mateix pes. Quant al retard, només es té en compte el que es produeix entre el connexionat de neurones i al model es pot veure representat com un interval de temps fix determinat pel retard observat anteriorment. Les neurones poden rebre senyals inhibitoris que desactiven totalment l'activitat de la neurona, en el model proposat per McCulloch i Pitts les neurones també poden rebre senyals inhibitoris, però per molt que rebin senyals totalment anàlegs, o sigui, senyals excitadors, les neurones queden totalment desactivades. I, finalment, l'estructura de la xarxa no varia amb el temps cosa que també succeeix en el model [12][13].

Tot i que és cert que el model McCulloch-Pitts no és adequat per descriure amb precisió les neurones com a entitats biològiques, des d'un punt de vista computacional ha estat una font d'inspiració per a molts models posteriors i continua sent un paradigma dins del camp de l'Enginyeria Neural.



## MARC TEÒRIC DEL TREBALL

### 2.1 Bispectral Index™ (BIS™) Monitoring System

És l'aparell que es fa servir per mesurar l'índex BIS i mostrar-lo per la HMI de l'aparell. Aquest valor es basa en diferents signes vitals i els analitza mitjançant diferents algorismes matemàtics fins aleshores desconeguts [14][15][16].

L'objectiu principal és proporcionar als pacients la dosi adequada d'anestèsia tenint en compte la hipnosi, l'analgèsia i la immobilitat del pacient.

La immobilitat és l'absència de moviments involuntaris, mentre que l'analgèsia és la disminució de resposta a estímuls desagradables per a les persones.

La hipnosi, en canvi, és la falta de consciència i fins ara ha sigut un repte poder mesurar-la.

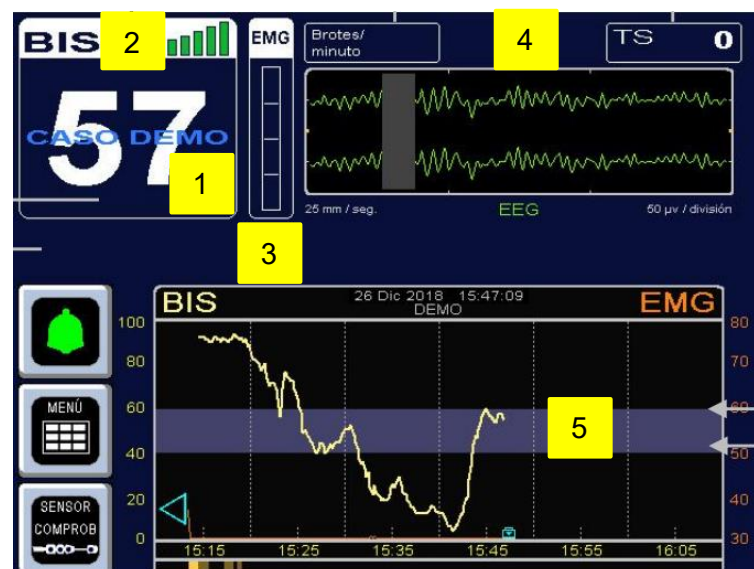
El BIS pot superar aquest repte analitzant la profunditat de sedació de l'anestèsia o sedació i directament mesurant l'efecte dels anestèsics i sedants al cervell.



**Fig. 3.** Components del sistema de monitorització completa BIS. Imatge extreta de Medtronic [17].

1. Monitor BIS
2. Cable d'interfase del monitor
3. BISx-LOC2 o BISx-LOC4
4. Cable d'interfase del pacient
5. Sensor BIS

La pantalla mostra principalment 5 indicadors importants. L'índex BIS, el senyal EEG, l'EMG, la gràfica del BIS i la qualitat de recepció dels senyals.



**Fig. 4.** Retall de la pantalla principal del monitor BIS. Imatge extreta del manual [18].

1. Valor del BIS
2. Qualitat del senyal
3. Potència (dB) de l'EMG
4. Forma d'ona de l'EEG
5. Gràfic de tendència del BIS i rang objectiu, si es necessita.

L'aparell, en funció del BISx-LOC2 o BISx-LOC4 pot llegir les senyals provinents del sensor de 2 canals o 4 canals, la diferència principal en ambdós mòduls és que els 4 canals poden detectar les diferències entre hemisferis [14][15].

Bàsicament, el BISx registra, filtra i processa els senyals EEG.

Com cal esperar també hi ha diferents tipologies de sensors en funció del seu ús i aplicació: *BIS Quatro Sensor (4 elèctrodes)*, *BIS Extend Sensor*, *Sensor BIS Bilateral*, and *the BIS Pediatric Sensor* [17]. Els valors mostrats, però, són els mateixos en funció del monitor o del sensor. Aquests oscil·len entre 0 i 100 depenent de l'activitat cerebral.

Valors BIS	Descripció
100	Activitat cerebral total
100-90	Despert/Totalment conscient
80-70	Sedat però conscient
70-60	Sedació profunda
60-40	Anestèsia general
40-20	Hipnosis profunda
20-0	Burst suppression*
0	Activitat cerebral nul·la

**Taula 2.** Valors BIS mostrats i la seva descripció [16].

\*Període d'alta activitat elèctrica alternada amb períodes de 0 activitat cerebral .

Aquests valors s'obtenen col·locant els sensors al lloc corresponent i aquests es transmeten mitjançant la connexió a un cable d'interfície de pacient (PIC). El senyal passa pel dispositiu BISx i pel cable d'interfície del monitor per assolir el resultat a l'HMI que mostra el valor final processat. Aquest monitor té una pantalla tàctil que permet modificar la configuració per part de l'usuari.

Actualment, a la unitat de cures pal·liatives, comencen a coexistir les escales observacionals (EO) i l'escala BIS. Totes dues han estat criticades i han generat una discussió controvertida sobre la seva utilitat i aplicació en el camp pal·liatiu. Les EO no són objectives, es basen en el punt de vista professional, i els valors BIS estan sota estudi, de manera que encara no s'hi confia gaire [18][19].

D'una banda, hi ha l'opinió que els valors BIS no són útils perquè les escales observacionals ja són suficients i l'ús d'un altre dispositiu podria ser impactant per a la família i el pacient. No obstant això, amb el BIS és possible obtenir registres del pacient en temps real, sense cap interpretació subjectiva [20], [21][22]. Per tant, l'índex bispectral no pot substituir les escales observacionals, però s'hauria de considerar la combinació de les dues, és a dir, utilitzar primer les escales observacionals i verificar els resultats amb una perspectiva objectiva.

Com s'ha dit anteriorment, les escales observacionals han estat objecte de crítiques. En l'ús d'aquestes escales, s'aplica un criteri basat en fets que no són objectius [23]. Les decisions de tractament o, dit d'una altra manera, la sedació, s'haurien de prendre en funció de les constants vitals, però això no és un fet. Es coneix que en alguns casos l'administració dels sedants es fa de manera subjectiva [24]. Aquesta decisió podria estar influïda pels sentiments o pensaments dels cuidadors, pel que veuen o recullen del pacient, i això no és acceptable per determinar l'estat del pacient d'una manera empírica [25]. La decisió ha de prendre's de la manera més objectiva possible.

Pel que fa a les escales observacionals, les més comunes i utilitzades són l'Escala de Sedació de Ramsay (RSS) i l'Escala d'Agitació i Sedació de Richmond (RASS), encara que també existeixen altres com l'Índex de Confort del Pacient (PCS).

L'escala RSS va ser la primera dissenyada per determinar el nivell de sedació del pacient, dividint aquest en sis categories que van d'1 a 6. L'índex de Bispectral (BIS) té una clara correlació amb els valors extrems de l'escala RSS, per exemple, un valor de 100 del BIS correspon a 1 de RSS, mentre que els valors de BIS de 20-0 corresponen a 6 a RSS.

Valors RSS	Descripció	Valors BIS
1	Totalment despert	100
2	Despert i relaxat	90
3	Adormit però respon a odors	80-70
4	Adormit però respon a estímuls	70-50
5	Adormit però respon al dolor	50-20
6	Son profund sense resposta	20-0

**Taula 3.** Valors de l'escala RSS vs BIS.

L'escala d'Agitació i Sedació de Richmond (RASS) [26], va ser dissenyada per determinar amb precisió el nivell de sedació del pacient. Es basa en deu graus que varien segons el nivell de sedació, que van de +4 a -5. Els valors van de +1 a +4, si el pacient està despert o agressiu, 0 correspon a un pacient tranquil i en alerta, mentre que de -1 a -5 el pacient es troba sedat.

Valors RASS	Descripció	Valors BIS
+4	Agressiu	100
+3	Molt agitat	100-90
+2	Agitat	90
+1	Inquiet/nerviós	80
0	Estat d'alerta però relaxat	80-70
-1	Adormit	60
-2	Sedació lleugera (respon a odors i estímuls)	60-50
-3	Sedació moderada respon a estímuls i dolor	40
-4	Sedació profunda (no respon)	20
-5	Sense activitat cerebral	0

**Taula 4.** Valors de l'escala RASS vs BIS [16][27].

És important tenir en compte que les escales observacionals estan basades en punts de vista subjectius dels professionals i poden conduir a malentesos i problemes com la sobre-sedació. En canvi, els valors de BIS són objectius, però encara s'estan investigant.

La sobre-sedació provoca que el temps de resposta/despertar-se sigui major, que es necessiti més estona ventilació assistida, més fàrmacs i, per tant, més cost i més temps d'estada a l'hospital, entre d'altres. En canvi, la sub-sedació genera ansietat i agitació, que la ventilació assistida sigui inefectiva, l'extracció inintencionada d'aparells mèdics, són alguns exemples [8][28][29].

Malgrat això, alguns estudis suggereixen que la combinació de mesures subjectives i objectives podria proporcionar una comprensió més precisa de la situació i el confort dels pacients. Tot i això, es necessita més investigació per comprendre millor el BIS i determinar la seva aplicabilitat en l'atenció pal·liativa.

En resum, és recomanable utilitzar el monitoratge de BIS en conjunt amb les escales observacionals per obtenir una informació més precisa i evitar problemes com la sobre-sedació. No obstant això, encara es necessita més investigació per determinar quines mesures són les més adequades i vàlides per utilitzar en pacients de cures pal·liatives. Cal comprendre perfectament el dispositiu, assegurar-se de la seva aplicació i provar la seva viabilitat, amb l'objectiu d'acceptar o rebutjar l'ús de l'índex bispectral en les cures pal·liatives.

Queda evident que es necessita més informació per garantir el benestar del pacient en situacions en què són vulnerables i en la fi de la vida. Per tant, és crucial realitzar estudis addicionals en aquest camp i en altres, com ara com els medicaments que poden afectar la senyal de l'EEG o l'índex bispectral, com les

malalties secundàries (si n'hi ha) poden afectar l'índex bispectral, com els efectes secundaris de qualsevol fàrmac, i també si hi ha variacions en funció de la malaltia que pateix la persona.

Cal augmentar el coneixement i la consciència en els hospitals sobre les necessitats actuals, per canviar alguns punts de vista de la recerca futura o canviar les variables a estudiar, el que milloraria la troballa de dades diferents. No obstant això, el que es pot assegurar és que la combinació de les escales observacionals i els valors de l'índex bispectral podria portar a una millora positiva en la qualitat d'una situació de fi de vida en cures pal·liatives.

## 2.2 Adquisició de dades

### 2.2.1.1 Procés d'obtenció de dades així com dels elèctrodes

Per a recopilar dades es fan servir uns elèctrodes que porten un teixit semblant a una esponja que ajuden a retenir el gel conductor que s'aplica per enganxar els elèctrodes i que hi hagi bona connexió [8]. Aquest teixit afegit a la tinta conductora i el foam adhesiu que envolta els dos primers components, conformen l'estructura d'un elèctrode.

Quan es volen posicionar els sensors cal fer una bona neteja de la zona per tal d'evitar que aquests es desenganxin.

Primer cal retirar la pell morta que es pot trobar a la zona amb una tovallola i després cal aplicar alcohol amb un cotó per tal d'eliminar el greix. Seguidament, es neteja amb aigua la zona per evitar que l'alcohol afecti el foam adhesiu. Una vegada s'ha executat el procés anterior es posa gel conductor a l'esponja del sensor i es posicionen al lloc corresponent.

S'ha de comprovar la correcta col·locació dels elèctrodes mitjançant el botó a l'HMI corresponent a: «Comprobación sensor» o connectant els elèctrodes al cable d'interfase del pacient. Per a un bon monitoratge el rang acceptable de resistència varia aproximadament entre 300Ω i 5kΩ.

### 2.2.1.2 3D

Per a realitzar aquesta primera versió del disseny de la diadema, s'ha emprat el programari Solidworks, concretament la versió de l'any 2022. Posteriorment, s'ha exportat el fitxer en format .stl per a poder realitzar una impressió 3D i afegir els elèctrodes.


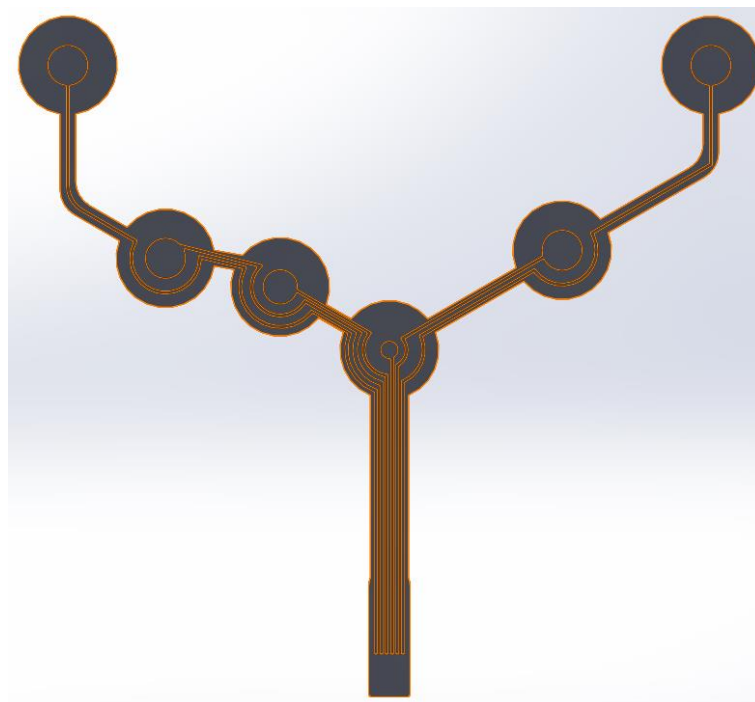


Fig. 5. Disseny de la diadema amb la posició dels sensors. Vista frontal.



**Fig. 6.** Disseny de la diadema amb la posició dels sensors.



**Fig. 7.** Disseny de la diadema amb les pistes dels sensors ressaltades.

### 2.2.1.3 Electrocompatibilitat

Una de les hipòtesis que van sorgir al graficar les dades d'EEG i EMG, és que els pics repetitius que es mostren podien ser provocats per interferències i soroll derivats dels aparells de la sala.




Fig. 8. Senyal EEG sense filtre.




Fig. 9. Senyal EMG sense filtre.

```

15 | 01/31/2023 13:14:40 > IMPEDNCE | 01/31/2023 13:14:40 | g 3000
16 | 01/31/2023 13:24:41 > IMPEDNCE | 01/31/2023 13:24:41 | g NOISE
17 | 01/31/2023 13:24:42 > IMPEDNCE | 01/31/2023 13:24:42 | g 2000
18 | 01/31/2023 13:24:43 > IMPEDNCE | 01/31/2023 13:24:43 | g 4000
19 | 01/31/2023 13:24:44 > IMPEDNCE | 01/31/2023 13:24:44 | g 3000
20 | 01/31/2023 13:24:45 > IMPEDNCE | 01/31/2023 13:24:45 | g 3000
21 | 01/31/2023 13:24:46 > IMPEDNCE | 01/31/2023 13:24:46 | g 3000
22 | 01/31/2023 13:24:47 > IMPEDNCE | 01/31/2023 13:24:47 | g 3000
23 | 01/31/2023 13:24:48 > IMPEDNCE | 01/31/2023 13:24:48 | g 3000
24 | 01/31/2023 13:34:49 > IMPEDNCE | 01/31/2023 13:34:49 | g NOISE
25 | 01/31/2023 13:34:50 > IMPEDNCE | 01/31/2023 13:34:50 | g 3000
26 | 01/31/2023 13:34:51 > IMPEDNCE | 01/31/2023 13:34:51 | g 3000
27 | 01/31/2023 13:34:52 > IMPEDNCE | 01/31/2023 13:34:52 | g 3000
28 | 01/31/2023 13:34:53 > IMPEDNCE | 01/31/2023 13:34:53 | g 3000
29 | 01/31/2023 13:34:54 > IMPEDNCE | 01/31/2023 13:34:54 | g 3000
30 | 01/31/2023 13:34:55 > IMPEDNCE | 01/31/2023 13:34:55 | g 2000
31 | 01/31/2023 13:34:56 > IMPEDNCE | 01/31/2023 13:34:56 | g 2000
32 | 01/31/2023 13:44:57 > IMPEDNCE | 01/31/2023 13:44:57 | g NOISE
33 | 01/31/2023 13:44:58 > IMPEDNCE | 01/31/2023 13:44:58 | g 3000
34 | 01/31/2023 13:44:59 > IMPEDNCE | 01/31/2023 13:44:59 | g 3000

```

Fig. 10. Arxiu de codi d'impedància dels sensors.

En aquestes línies de codi de la Fig. 10 es pot observar que cada 10 min justos, s'observa soroll. Pot ser donat per un mal contacte dels sensors, però en ser un fet tan periòdic no ho sembla pas sinó més ben dit soroll de la sala. Per culpa d'aquestes interferències es decideix fer un estudi d'electrocompatibilitat i els resultats d'aquest asseguren que els instruments de la sala de l'UCI, sí afecten el senyal.

Es va fer un registre de les interferències a una freqüència de mostreig de 100Hz, el mateix dia, amb els sensors d'un mòbil Android i l'aplicació de Matlab. Per a l'obtenció de dades, es va fer un recull en una taula de les combinacions possibles essent ON mode encès i OFF mode apagat.

Els resultats obtinguts demostren, com es d'esperar, que la situació idònia per al registre del BIS correspon a la desconnexió total dels aparells de la sala. El valor de camp magnètic [B] mitjà correspon a 46,86  $\mu\text{T}$  i el pic de la FFT és de 0,28.

B mitja ( $\mu\text{T}$ )	FFT Pic	Televisió	Nevera	Aire condicionat	Llit	Bomba d'infusió	Sistema de trucada
46,86	0,28	OFF	OFF	OFF	OFF	OFF	OFF

Un fet destacable és que les pitjors condicions no es donen quan tots els aparells es troben en funcionament, sinó quan l'aire condicionat, el llit i la bomba d'infusió estaven encesos i la resta apagats. Els valors del primer cas, quan tot estava encès corresponen a una B mitja de 91,30 i la FFT pic de 1,08, i en el segon cas la B mitja és de 92,16 i el pic de FFT de 1,21.

B mitja ( $\mu\text{T}$ )	FFT Pic	Televisió	Nevera	Aire condicionat	Llit	Bomba d'infusió	Sistema de trucada
91,30	1,08	ON	ON	ON	ON	ON	ON

B mitja ( $\mu\text{T}$ )	FFT Pic	Televisió	Nevera	Aire condicionat	Llit	Bomba d'infusió	Sistema de trucada
92,16	1,21	OFF	OFF	ON	ON	ON	OFF



Un resultat rellevant que s'ha detectat és que la televisió i la nevera no afecten notablement a el senyal quan estan enceses, una de les hipòtesis que van sorgir principalment era que aquests aparells influeixen més que la resta per la seva proximitat al llit, però s'ha comprovat que no.

S'ha demostrat que la presència d'artefactes a les habitacions pot tenir repercussions en el senyal del pacient, la qual cosa avala la hipòtesi de l'associació de l'entorn amb la qualitat del senyal. Per això cal evitar-los si això és possible.

### 2.3 Identificació de sistemes

Per a poder realitzar un correcte estudi sobre les diverses alternatives que existeixen per reproduir el BIS, s'opta per fer una comparativa entre els models lineals i els no lineals. S'estudiaran concretament els models ARX i els OE per a models lineals i els NNARX i NNOE per a models no lineals. Partim d'un sistema de caixa negra, això significa que només són coneguts els paràmetres d'entrada i els de sortida, però no se sap que passa en aquest sistema per obtenir els resultats [30][31].

Per a seleccionar quin model és el més adequat es farà servir l'MSE i l'FPE.

$$MSE = \frac{1}{N} * \sum_{t=1}^N (y_t - f_t)^2 \quad (1) \qquad FPE = \det|MSE| * \left( \frac{1 + \frac{d}{N}}{1 - \frac{d}{N}} \right) \quad (2)$$

A l'MSE, N és el nombre de dades del senyal,  $y_t$  representa les dades reals i  $f_t$  són les dades predites. No obstant això, en el codi es va utilitzar la funció ja existent de Matlab anomenada 'mse'.

A l'FPE, N representa el nombre de dades del senyal, i d és la suma dels paràmetres na i nb. En aquest cas, també es va utilitzar la funció ja existent de Matlab anomenada 'fpe'.

#### 2.3.1 Models lineals

Els models lineals que s'estudiaran principalment són dos: l'OE i l'ARX. Cal destacar que aquest projecte en concret s'ha centrat en l'OE i la meua companya Carlota Lacasa ha fet la feina de l'ARX i, per tant, d'aquest model repetiré les seves paraules.

##### 2.3.1.1 OE




Fig. 11. Estructura d'un model OE.

Font: [30]

Un model output error, és aquell que es basa en simulació pura, no necessita mesures experimentals de sortida anteriors a l'instant actual per a poder simular resultats. Els OE destaquen per afegir l'error al final del sistema, o sigui el soroll és l'única diferència entre la sortida actual i la sortida sense cap error aplicat.

L'equació que representa el model és la següent:

$$y(t) = \frac{B(q)}{F(q)} u(t-nk) + e(t) \quad (3)$$

On  $y(t)$  és la sortida,  $u(t)$  és l'entrada i  $e(t)$  és l'error.

A Matlab la funció es defineix com:

`sys = oe(tt,[nb nf nk]);`

Els ordres [nb nf nk] defineixen el nombre de paràmetres de cada component del polinomi estimat, de manera següent:

nb: Ordre del polinomi  $B(q) + 1$ , que és equivalent a la longitud del polinomi  $B(q)$ .


nf: Ordre del polinomi  $F$ .

nk: Retard de l'entrada, expressat com el nombre de mostres.

### Ordre del sistema: valors de [nb nf nk]:

Hi ha combinacions que no tenen sentit. El polinomi  $B(z)/F(z)$  és una funció de transferència discreta. És una funció pròpia, això significa que el polinomi  $B$  no pot tenir un ordre superior al polinomi  $F$ . Per tant, el valor  $B < F$ .

Una vegada acotats els valors nb i nf, apliquem una anàlisi de correlació per definir nk. Això ajuda a inferir quin valor de nk es podria utilitzar aplicant una funció ja existent a Matlab anomenada 'cra', que estima la resposta impulsional per a les dades en el domini del temps i les representa gràficament. Estadísticament, aquesta correlació creuada mostra com de relacionada estan l'entrada real i el senyal predit. Es basa en un interval de confiança del 95%, per tant, l'impuls que roman dins del llindar no és estadísticament significatiu.



**Fig. 12.** Anàlisi de correlació sense cap mostra de retard.

Aquesta anàlisi el que fa és una correlació creuada. Si tenim dos vectors, un d'ells el gira i els fa coincidir en la primera mostra. A partir d'aquí fa la correlació i detecta si hi ha una relació causal entre vectors. Per exemple: si veu que durant 5 mostres no hi ha relació aquestes són les mostres de retard.

Una de les comprovacions que es poden fer per veure si les mostres de retard són les adequades és mirar el fit del sistema en funció de l'ordre.

Per exemple: Tenim un sistema al qual li apliquem un ordre [1 1 1] del qual s'extreu un fit del 40%. Repetim el mateix pels ordres [1 1 2], [1 1 3], [1 1 4], [1 1 5], [1 1 6], [1 1 7] amb els fits corresponents 44%, 50%, 56%, 74,36%, 85% i 60%. Veiem que el retard del sistema correspon a 6 mostres, perquè el fit ha anat incrementant en relació amb l'ordre i a la que el nombre de mostres ha sigut massa elevat pel sistema el fit ha disminuït.

Quant al model oe, es van elaborar dos tipus en funció de les dades utilitzades. Per una part hi ha el model basat en els senyals electromiogràfics (EMG) utilitzats com a dades d'entrada i l'índex bispectral (BIS) com a dades de sortida, i, per una altra part, estan les dades electroencefalogràfiques (EEG) utilitzades com a entrada i el senyal BIS com a sortida. En ambdós casos la sortida és la mateixa i l'única variació són les dades d'entrada. D'aquesta manera podem veure quines dades són les més eficaces per simular un model que proporcioni resultats prometedors.



Perquè els resultats siguin acceptables s'han de seguir certs criteris. La qualitat del model està relacionada amb:

1. El seu ús. Ja que un model pot ser excel·lent per al disseny de control però inadequat per a la simulació.
2. La capacitat d'aquest per reproduir el comportament del sistema.
3. L'estabilitat del model. Com de bé es pot reproduir el model a partir de diferents conjunts de dades.

### 2.3.1.2 ARX

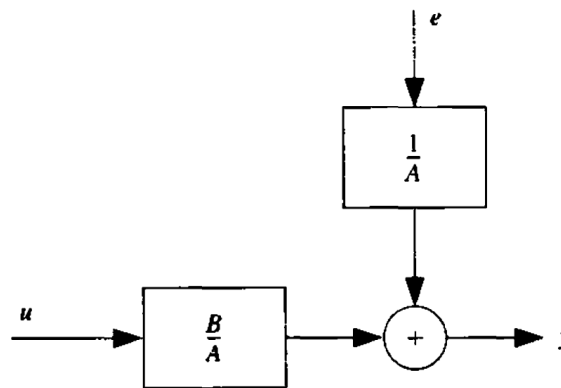


Fig. 13. Estructura d'un model ARX.

Font: [30]

Un model d'AutoRegressive eXogeneous variable, és aquell que es basa en la predicció, necessita mesures experimentals de sortida anteriors a l' instant actual per a poder predir resultats. Una característica dels ARX és que contenen dins del sistema la dinàmica de l'error.

L'equació que representa el model és la següent:

$$y(t) = \frac{B(q)}{A(q)} u(t) + \frac{1}{A(q)} e(t) \quad (3)$$

On ,  $y(t)$  és la sortida,  $u(t)$  és l'entrada i  $e(t)$  és l'error.

A Matlab la funció es defineix com:

`sys = arx(tt,[na nb nk]);`

Els ordres [na nb nk] defineixen el nombre de paràmetres de cada component del polinomi estimat, de manera següent:

na: Ordre del polinomi  $A(q)$ .

nb: Ordre del polinomi  $B(q) + 1$ .

nk: Retard de l'entrada, expressat com el nombre de mostres.

### 2.3.2 Models no lineals


Les xarxes neuronals es comporten de manera semblant a les xarxes biològiques humanes, com per exemple: Són capaces d'aprendre a través del que se'ls hi ha ensenyat prèviament, poden generalitzar basant-se en casos anteriors i poden abstrure les dades rellevants dels conjunts de dades [7].

Bàsicament, el funcionament d'aquestes rau en una combinació d'entrades que acostuma a ser una suma bàsica, a aquest resultat se li aplica una funció i s'obté la sortida. En aquests models, és important considerar que la sortida d'una neurona normalment és una de les entrades d'una altra neurona artificial, d'aquí neixen les estructures interconnectades. Les xarxes en funció de la seva arquitectura es poden agrupar per nombre de capes (Fig.13 i 14 ), per tipus de connexió (Fig.15 i 16) i per grau de connexió [12][13].


Si s'agrupen en xarxes monocapes, significa que només hi ha una capa de neurones. Per contra, les xarxes multicapa tenen entre les neurones d'entrada i les de sortida, unes capes ocultes.

El tipus de connexió pot variar entre xarxes recurrents i no recurrents. Les primeres reben retroalimentació de neurones de la mateixa capa, de diferents capes o de les mateixes neurones.


El grau de connexió va lligat a les xarxes totalment o parcialment connectades. Les xarxes totalment connectades es caracteritzen per tenir totes les neurones d'una capa connectades a la següent, en canvi, en les parcialment connectades no existeix connexió entre totes les neurones. [1]




**Fig. 14.** Xarxes monocapes.  
Font: [1]



**Fig. 15.** Xarxes multicapa.  
Font: [1]



**Fig. 16.** Xarxes no recurrents.  
Font: [1]



**Fig. 17.** Xarxes recurrents.  
Font: [1]

S'estudiaran principalment dos models no lineals: l'NNOE i l'NNARX. Cal destacar que aquest projecte en concret s'ha centrat en l'NNOE i la meua companya Carlota Lacasa ha fet la feina de l'NNARX i, per tant, d'aquest model repetiré les seves paraules.

### 2.3.2.1 NNARX

L'estudi de l'índex BIS basat en un nou model per al monitoratge de la consciència durant la sedació pal·liativa es va produir de manera similar als altres models ja explicats. Es va aplicar un filtre per eliminar el soroll que es trobava a ambdós senyals, i es van dividir en dues parts, respectivament, per tenir els conjunts d'ajust i validació. Es va fer servir el mateix procés que en els models lineals. No només es necessita un pre-processament del senyal i la seva respectiva divisió de les dades, sinó també entrenar el model i provar-lo.

En aquest cas, però, als models no lineals es van analitzar emprant una única entrada, que podia ser el senyal d'EEG o d'EMG, i com a sortida el BIS, això va ser a conseqüència del temps.

La definició de les estructures va ser senzilla, com 3 neurones hiperbòliques (HHH), 1 lineal (L) i 2 ocultes (--), ja que ja s'havia demostrat en els models lineals que l'índex BIS no necessita ordres grans. Cal posar èmfasi en el fet que com més complexa sigui la xarxa neuronal, més precisa serà, però més trigarà a executar-se.

També ha d'haver-hi el mateix nombre de neurones a cada costat, per tant, si hi ha 3 neurones hiperbòliques a la part esquerra, s'han d'afegir 3 neurones més a la dreta, independentment de què aquestes siguin lineals o ocultes. El nom de la neurona depèn de la seva funció d'activació, la lineal [L] s'anomena així a causa de la combinació lineal de pesos i entrades, sent la més senzilla però limitada computacionalment. En canvi, la funció d'activació hiperbòlica [H] té aquest nom a causa de la seva tangent hiperbòlica simètrica i contínua. Cal dir que, tot i tenir només una sortida, en la programació s'ha d'equilibrar afegint '- ', que són les capes ocultes. Es va provar des d'1 neurona fins a 3 d'elles, amb totes les variacions que pogués haver-hi. NetDef = ['H' 'L'], NetDef = ['HH' 'L-'], NetDef = ['HHH' 'L--'].

A l'hora d'estructurar la xarxa, es va utilitzar el mateix retard (nk) que en els models lineals perquè funcionava correctament. Després, la xarxa neuronal es va entrenar establint l'estructura que s'havia de seguir, on els paràmetres es van ajustar a 0 per entrenar l'algorisme, així com fent servir la funció 'nnet' i aplicant els senyals com a conjunt d'entrenament. Es necessitava un procediment de validació per avaluar com de bé s'ajustava la xarxa neuronal al model real.

La funció 'nnet' a Matlab proporciona diferents gràfics. A la primera figura que s'obre, el primer gràfic que es mostra superposa el model real i el model estimat, el que ajuda a veure com de bé s'ajusta el model a un pas endavant. El segon és l'error de predicció del model.

A continuació, apareix un gràfic de la funció d'autocorrelació de l'error de predicció, que és útil per avaluar si hi ha alguna repetició, ja que es basa en la correlació d'un senyal amb ell mateix. En conseqüència, quan el valor és 1, significa que és idèntic, però baixarà a mesura que es desviï de si mateix. A més, mostra dues línies puntejades que representen el nivell significatiu i que es calculen fent 3 vegades la desviació estàndard.

L'últim gràfic que apareix en aquesta funció és un histograma amb l'error d'estimació. No obstant això, aquesta funció té un problema, ja que valida a un horitzó d'una mostra, per tant, aquesta verificació sempre donarà bons resultats. En conseqüència, per determinar si aquest grau dels regressors és correcte i l'estructura de la xarxa neuronal, es va utilitzar la funció 'kpredict', pel fet que els horitzons es poden modificar.

Es van modificar els horitzons com en els models lineals (1, 10, 60 i 120) i es proporciona un gràfic amb els dos models, el real i l'estimat. Per seguir la mateixa estructura que en els models lineals, es van repetir els models no lineals, però amb diferents ordres i/o estructures en cada model, diferenciats pel nombre de canals, nombre de senyals o tipus de senyal. En conseqüència, es va realitzar una taula d'Excel amb les xarxes neuronals descrites, els seus horitzons i ordres, per avaluar si hi havia algun canvi o quin mostrava els millors resultats.

Per a poder executar els models d'aquesta estructura primer de tot cal descarregar l'add-on de Matlab anomenada 'nnsysid' feta per Magnus Nørgaard [32], aquesta va permetre utilitzar certes funcions necessàries per construir una xarxa neuronal.

### 2.3.2.2 NNOE

El cas de l'aplicació del model no lineal OE va ser molt semblant als models lineals i al model no lineal nnarx. Primer es necessita un pre-processament del senyal i la seva respectiva divisió de les dades en vector d'ajust i vector de validació, a més del posterior entrenament de la xarxa neuronal artificial i la seva posada en pràctica.

Igual que en el cas anterior, només es va fer servir una entrada (EMG) i una sortida (BIS) per a validar el model. L'ordre escollit és el mateix que en els models lineals, concretament en el model oe, nb=2; nf=3; nk=0; i, com a estructura de xarxa neuronal, s'utilitzen també 3 neurones hiperbòliques (HHH), 1 lineal (L) i 2 ocultes (--).

Primer de tot, els paràmetres es van ajustar a 0 per entrenar l'algorisme, així com fent servir la funció 'nnoe' i aplicant els senyals com a conjunt d'entrenament.

```
[P1,P2]=nnoe(NetDef,NN,[],[],trparms,sort_entrenament',ent_entrenament');
```

L'índex de minimització o índex d'error ha de tendir a 0 i el resultat del valor obtingut correspon a 12,94. Si es compara amb les primeres iteracions, aquest valor és molt correcte, ja que es parla de valors oscil·lants a 23, es redueix a la meitat.

La funció 'nnvalid' a Matlab proporciona la superposició del model real amb l'estimat, l'error de predicció que s'assoleix del model, la funció d'autocorrelació de l'error de predicció i l'histograma de l'error de predicció.

```
[yhat,NSSE]=nnvalid('nnoe',NetDef,NN,[P1],P2,sort_validacio',ent_validacio');
```

Tanmateix, aquests resultats no són prou fiables, ja que valida a un horitzó d'una mostra, per tant, per determinar si aquest grau dels regressors és correcte es fa servir la funció 'kpredict', en aquesta els horitzons es poden modificar.

Els horitzons escollits van ser (1, 10, 25, 50 i 100) i es genera un gràfic amb els dos models, el real i l'estimat.

```
Ypred1=kpredict('nnoe',NetDef,NN,1,[P1],[P2],sort_validacio',ent_validacio');
Ypred10=kpredict('nnoe',NetDef,NN,10,[P1],[P2],sort_validacio',ent_validacio');
Ypred25=kpredict('nnoe',NetDef,NN,25,[P1],[P2],sort_validacio',ent_validacio');
Ypred50=kpredict('nnoe',NetDef,NN,50,[P1],[P2],sort_validacio',ent_validacio');
Ypred100=kpredict('nnoe',NetDef,NN,100,[P1],[P2],sort_validacio',ent_validacio');
```

Per a poder executar els models d'aquesta estructura primer de tot cal descarregar l'add-on de Matlab anomenada 'nnsysid' feta per Magnus NØrgaard.

## ANÀLISI DE METODOLOGIES CANDIDATES



**Fig. 18** Diagrama de l'anàlisi de metodologies candidates.

Quan es va plantejar per primera vegada la problemàtica a resoldre, no se sabia ben bé com encarar-la. Primer de tot s'havia de superar el repte d'aconseguir les dades necessàries per a processar. No va ser una tasca fàcil, a causa del fet que són dades de pacients i per tema privacitat de dades, els hospitals són molt reticents a cedir-les, cosa totalment comprensible. Però per sort, aquesta tipologia de dades no conté cap distintiu que les vinculi a cap pacient, en cap moment es mostren dades que necessitin privacitat, ja que no contenen dades personals.

Gràcies a això, es va parlar amb tres hospitals diferents per a la cessió d'aquestes, l'hospital General de Catalunya, l'hospital de la Vall d'Hebron i l'Hospital Clínic. Del primer hospital vam obtenir dades de 4 canals, dades que no ens servien gaire ja que el nostre codi servia per a 2 canals i s'hauria d'haver redissenyat. El segon hospital va proporcionar les dades necessàries de 2 canals i del tercer no es va obtenir resposta.


Quan es van tenir les dades pre-processades, es va haver de decidir quins models s'utilitzarien per a la predicció/simulació del sistema. Inicialment, es van decidir fer dos models lineals i dos no lineals, per qüestió de temps i van ser l'OE, l'ARX, l'NNOE i l'NNARX.

## METODOLOGIA MODELS LINEALS

### 4.1 Model OE d'1 entrada

En aquest apartat es desenvoluparà la metodologia emprada mitjançant el codi Matlab per obtenir els resultats finals.


En primera instància s'explicarà el procediment del model lineal OE.



**Fig. 19.** Diagrama del model lineal OE amb 1 entrada.


El primer pas és llegir les dades amb el codi desenvolupat a Matlab. Cal llegir i graficar els senyals d'EMG, EEG i BIS. Quant a les dades de l'EEG cal mencionar que se'ls hi aplica una mitja als 4 canals per tal de poder treballar amb un vector d'una columna i veure un senyal representat, no quatre.

*NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.1/ 10.7.3/ 10.7.5 dels Annexos.*




**Fig. 20.** Senyal EMG (entrada).

Eix x: Temps [seg]  
Eix y: Amplitud [ $\mu$ V]



**Fig. 21.** Senyal EEG (entrada).

Eix x: Temps [seg]  
Eix y: Amplitud [ $\mu$ V]



**Fig. 22.** Senyal BIS (sortida).

Eix x: Temps [seg]  
Eix y: Amplitud [ $\mu$ V]

Com es pot observar a la fig.15 i a la fig.16, apareix un senyal periòdic el qual es tractarà com a soroll, perquè en trobar-se l'aparell a una sala d'UCI i després d'aplicar l'estudi d'electrocompatibilitat, es determina que són interferències provocades per algun altre aparell de la sala. A més es veu que els pics apareixen cada 600 mostres, en el cas de l'EMG, i el seu temps de mostreig és  $T_s=1$ . Per tant, els pics apareixen cada 600 segons que equivalen a 10 min. Aquesta informació va ser contrastada amb la doctora de la Vall d'Hebron i va confirmar que aquest senyal periòdic cada 10 minuts, podia ser provocat perfectament per qualsevol aparell integrat als monitors generals com poden ser els que mesuren la pressió arterial.


Per tal d'erradicar aquests pics no propis del senyal s'aplica un filtre gaussià de doble passada, per evitar canviar la fase del senyal. El codi és el següent:

```

%Gaussian filter
Window= 30;
BISfiltrat = smoothdata(BIS, "gaussian", Window);
  
```


En funció del senyal es va variar la finestra del filtre. A l'EEG s'aplica una finestra equivalent a 200, a l'EMG la finestra és 30 i al BIS s'aplica una de 30.

*NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.2/ 10.7.4/ 10.7.8 dels Annexos.*




**Fig. 23.** EMG vs EMG Filtrat.

Eix x: Temps [seg]  
Eix y: Amplitud [µV]



**Fig. 24.** EEG vs EEG Filtrat.

Eix x: Temps [seg]  
Eix y: Amplitud [µV]



**Fig. 25.** BIS vs BIS Filtrat.

Eix x: Temps [seg]  
Eix y: Amplitud [µV]


Una vegada estan els senyals filtrats, s'executa una correlació normalitzada entre les dades d'EMG i BIS i les dades d'EEG i BIS, per tal d'avaluar les similituds entre ambdós senyals comparades. Es normalitzen per eliminar les diferències en amplitud i es corrobora una comparativa consistent.

**% Correlació normalitzada entre senyals**

```
[c,lags] = xcorr(EMGfiltrat-mean(EMGfiltrat),BISfiltrat-mean(BISfiltrat),'normalized');
figure(6);
stem(lags,c);
title('Correlació entre el senyal EMG i el BIS');
[c1,lags1] = xcorr(EEGfiltrat(1:15536)-mean(EEGfiltrat(1:15536)),BISfiltrat-mean(BISfiltrat),'normalized');
figure(7);
stem(lags1,c1);
title('Correlació entre el senyal EEG i el BIS');
```


Com es pot observar en les següents figures, la més apropiada correspon a la correlació entre EMG i BIS, ja que l'índex de correlació (eix d'ordenades) és més proper a 1. Es troba al voltant de 0,8 en contraposició al 0,3 del senyal EEG, això significa que existeix una relació lineal forta i positiva (si una variable augmenta, l'altre també ho fa). A més, en el senyal EMG es veu un retard temporal ínfim (molt proper a 0) comparat amb el senyal d'EEG (difereix de 0 i a més és negatiu).

*NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.10/ 10.7.11 dels Annexos.*



**Fig. 26.** Correlació entre EMG i BIS.

Eix x: Retard temporal [seg] →  $T_s=1$  seg  
Eix y: Similitud [tant per u]



**Fig. 27.** Correlació entre EEG i BIS.

Eix x: Retard temporal [seg] →  $T_s=0.0156$  seg  
Eix y: Similitud [tant per u]


Tan bon punt s'ha decidit quin senyal fer servir, en aquest cas el senyal EMG, cal dividir el vector de dades en les dades d'entrenament/ajust i les dades de validació.



**%% Divisió del senyal en dades d'entrenament i dades de validació**


```
ent_entrenament = EMGfiltrat(1:7768,:);
ent_validacio = EMGfiltrat(7769:15536,:);
sort_entrenament = BISfiltrat(1:7768,1);
sort_validacio = BISfiltrat(7769:15536,1);
```

NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.12/ 10.7.13 dels Annexos.



**Fig. 28.** Senyal EMG i BIS.

Eix x: Temps [seg]  
Eix y: Amplitud [µV]




**Fig. 29.** Senyal EEG i BIS.

Eix x: Temps [seg]  
Eix y: Amplitud [µV]

A continuació es continua el procediment associat a l'assignació de l'ordre del model. El primer pas és aplicar la funció de matlab 'cra' que correspon a l'índex de correlació. Com s'ha explicat anteriorment, aquest serveix per a determinar les mostres de retard del model.


```
ir=cra(d,20);
xlabel 'Nº Mostra'
ylabel 'Amplitud'
```

NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.14/ 10.7.15 dels Annexos.



**Fig. 30.** Resposta impulsional estimada del senyal EMG.

Eix x: N° mostra  
Eix y: Amplitud



**Fig. 31.** Resposta impulsional estimada del senyal EEG.


Eix x: N° mostra  
Eix y: Amplitud

Una vegada s'identifiquen les mostres, s'aplica un impuls d'un graó amb la funció 'cumsum' per simular la resposta del model.

```
sr=cumsum(ir);
figure(10)
plot(sr)
xlabel 'Nº Mostra'
ylabel 'Amplitud'
title 'Resposta a un graó'
```




NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.16/ 10.7.17 dels Annexos.



**Fig. 32.** Resposta a un graó senyal EMG.

Eix x: N° mostra

Eix y: Amplitud



**Fig. 33.** Resposta a un graó senyal EEG.

Eix x: N° mostra

Eix y: Amplitud

Seguidament, amb programació de matlab, s'acaba de definir l'ordre del sistema. Es miren els ordres definits a la taula 5 i s'escull el que menys mse i fpe té. Cal destacar que normalment l'ordre que millors resultats dona, resulta ser gran i això fa complica la seva implementació, ja que a més ordre, més temps d'execució cal. En aquest cas s'escull l'ordre 230 com a model resultant, perquè tot i no tenir el valor d'mse més baix, és cert que només difereix en 0,45 unitats. L'error és més que acceptable, perquè disminuïm d'un ordre 670 a un 230.

%% OE 230

```
%Transference function calculation
GdeY230=oe(d,[2 3 0]);
GdeY230.Ts=Ts;
%Simulation
ysim230=lsim(GdeY230,ent_validacio,T);
%ERROR
error230=sort_validacio-ysim230;
%MSE
mse230=GdeY230.Report.Fit.MSE;
%FPE
fpe230=GdeY230.Report.Fit.FPE;
%Plot
subplot(2,2,2)
compare(d,GdeY230)
```

OE	EMG		EEG	
	MSE	FPE	MSE	FPE
120	54,19	54,26	131,84	131,85
130	54,37	54,47	351,23	351,23
140	651,20	652,04	132,10	132,10
150	192,73	193,03	149,98	149,99
220	35,90	35,95	131,65	131,65
230	28,70	28,76	117,11	117,11
240	51,05	51,13	117,11	117,11
250	61,21	61,32	117,10	117,11
330	28,71	28,78	131,12	131,12
340	28,68	28,76	129,78	129,78
350	28,65	28,75	131,56	131,56
440	28,55	28,64	131,32	131,32
450	49,24	49,36	131,14	131,14
550	48,81	48,93	116,50	116,51
560	54,95	55,10	118,10	118,11
570	28,30	28,44	131,16	131,17
660	71,50	71,73	145,18	145,18
670	28,25	28,40	116,43	116,44
770	31,00	31,17	107,28	107,29

**Taula 5.** Resultats MSE i FPE de models OE d'una entrada

## 4.2 Model OE 2 entrades

Un cop realitzat l'estudi d'una entrada, el senyal EMG, es procedeix a analitzar els resultats però amb ambdós variables, els senyals EMG i EEG combinats com a entrada, i el BIS com a sortida. Donats aquests resultats, es pot decidir és convenient treballar amb dues variables d'entrada o si és més eficient treballar amb una sola.




Fig. 34. Diagrama del model OE amb 2 entrades.

S'aplica el mateix procediment anterior però amb els senyals d'EMG i d'EEG com a variables d'entrada i el BIS com a senyal de sortida:

OE	MSE	FPE	OE	MSE	FPE
120	64,06	64,07	350	35,04	35,04
130	249,69	249,70	440	28,45	28,45
140	125,49	125,50	450	35,62	35,62
150	37,65	37,65	550	34,41	34,41
220	59,10	59,10	560	79,75	79,76
230	29,31	29,31	570	28,46	28,46
240	28,89	28,89	660	34,31	34,31
250	29,51	29,51	670	34,30	34,31
330	36,53	36,53	770	34,36	34,37
340	38,06	38,06			


Taula 6. Resultats MSE i FPE de models OE de dues entrades.

En aquest segon cas, el millor ordre seria el 440. L'MSE equival a 28,45, valor major a l'ordre 230 del senyal EMG.

### 4.3 Mínim conjunt de dades


Una vegada s'ha decidit l'ordre del model més adequat i el senyal a utilitzar, es busca el mínim conjunt de dades necessàries per a poder arribar a la solució desitjada. O sigui si per arribar a l'objectiu es poden fer servir, per exemple 100 dades, no cal agafar-ne 10000, ja que seria una pèrdua de temps i d'eficiència.

*NOTA: Els gràfics es poden veure ampliats a l'apartat 10.7.36/ 10.7.45 dels Annexos.*




**Fig. 35.** 10%\* de dades utilitzades d'EMG.

Eix x: Temps [seg]  
Eix y: Amplitud




**Fig. 36.** Comparativa entre les dades de validació i el model escollit.

Eix x: Temps [seg]  
Eix y: Amplitud



**Fig. 37.** 100%\* de dades utilitzades d'EMG.

Eix x: Temps [seg]  
Eix y: Amplitud



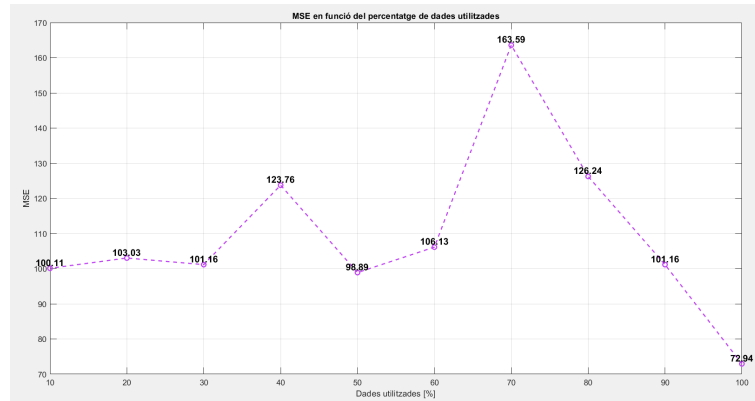
**Fig. 38.** Comparativa entre les dades de validació i el model escollit.

Eix x: Temps [seg]  
Eix y: Amplitud

\* Es poden trobar els diferents gràfics de les dades utilitzades en increments del 10% a l'apartat 10.7.36 dels Annexos.

En el següent gràfic es mostra la variació de l'mse en funció de les dades emprades amb un increment del 10%. En aquest cas l'mse que s'agafa és el següent:  $mse_{230} = mse(error_{230})$ ; S'escull aquest perquè s'entrena cada vegada amb un conjunt de dades més pobre, disminueix en nombre i, per tant, es compara amb el mateix vector de dades.

*NOTA: Els gràfics es poden veure ampliats a l'apartat 10.7.46 dels Annexos.*




**Fig. 39.** Variació de l'mse en funció del % de dades utilitzades.

Eix x: Dades utilitzades [%]

Eix y: Valor mse

S'ha mencionat anteriorment que es busca el menor rang de dades necessàries per a obtenir el resultat desitjat, per tant, es farà una anàlisi del primer 10% i un del 10% final de les dades. Com es pot observar a les següents figures, en el cas del 10% inicial, és indiferent agafar entre l'1% i el 6% de les dades, ja que l'mse no varia gaire. En el cas del 10% final, passa ben bé el mateix, és indiferent escollir el 92% de les dades o el 100%.


*NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.47/ 10.7.48 dels Annexos.*



**Fig. 40.** 10% inicial de dades.

Eix x: Dades utilitzades [%]

Eix y: Valor mse




**Fig. 41.** 10% final de dades.

Eix x: Dades utilitzades [%]

Eix y: Valor mse


S'apliquen els models de d'ordre 230, a l'1%, al 10% i al 100% de les dades utilitzades per veure les diferències entre els conjunts fets servir. A primera vista, els gràfics no difereixen gaire, si és cert que el fit varia, però es pot veure que el model segueix molt bé la tendència de les dades de validació en els tres casos, no s'aprecia una millora notable entre l'1% de dades i el 100%.

*NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.49/ 10.7.50/ 10.7.51 dels Annexos.*




**Fig. 42.** Model oe de l'1% de dades utilitzades.

Temps [seg]  
Eix y: Amplitud



**Fig. 43.** Model oe del 10% de dades utilitzades.

Temps [seg]  
Eix y: Amplitud




**Fig. 44.** Model oe del 100% de dades utilitzades.

Temps [seg]  
Eix y: Amplitud


Per veure numèricament l'error dels models s'aplica un histograma en funció del percentatge de dades utilitzat.

NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.52/ 10.7.53/ 10.7.54 dels Annexos.




**Fig. 45.** Error de l'1% de dades utilitzades.

Eix x: Percentatge de l'error [%]  
Eix y: Repetició de l'error [uds]



**Fig. 46.** Error del 10% de dades utilitzades.

Eix x: Percentatge de l'error [%]  
Eix y: Repetició de l'error [uds]



**Fig. 47.** Error del 100% de dades utilitzades.

Eix x: Percentatge de l'error [%]  
Eix y: Repetició de l'error [uds]

#### 4.4 Model ARX d'1 entrada

La implementació del model ARX va ser similar al model OE. Es van realitzar dos tipus de models, el primer utilitzava el senyal EMG com a entrada i el senyal BIS com a sortida, i el segon agafava el senyal EEG com a entrada i el BIS com a sortida.

Un cop els senyals van estar processats i separats en dades d'ajust i de validació, es va dur a terme el model predictiu ARX amb la part d'entrenament per conèixer la funció de transferència.

Es va aplicar un ordre determinat, que es va anar canviant cada vegada per provar l'efectivitat i trobar el millor rendiment. Aquest ordre podria ser infinit, però es va delimitar per poder analitzar els resultats. Per conèixer el millor valor de  $n_k$ , conegut com a retard, es va aplicar una anàlisi de correlació, mencionat a l'apartat anterior de l'oe i es va analitzar l'mse.


La predicció es va dur a terme a quatre horitzons diferents: 1, 10, 60 i 120. Això indica fins a quin punt el model està fent la predicció. L'esperat era observar un empitjorament dels resultats a mesura que l'horitzó augmenta, ja que la precisió disminueix i així es pot corroborar en la taula 7 i 8. L'ordre finalment escollit per les dades EMG va ser el 520 i per les dades EEG el 510.

EMG				EEG			
Ordre	Horitzó	MSE	FPE	Ordre	Horitzó	MSE	FPE
520	1	$8,76 \cdot 10^{-5}$	$8,77 \cdot 10^{-5}$	510	1	$6,90 \cdot 10^{-7}$	$6,90 \cdot 10^{-7}$
	10	1,3013	1,3000		10	$9,42 \cdot 10^{-4}$	$9,42 \cdot 10^{-4}$
	60	77,9938	78,0000		60	0,2626	0,2630
	120	96,6822	96,7000		120	0,9380	0,9380


**Taula 7.** Resultats de l'MSE i FPE amb l'ordre definit.

**Taula 8.** Resultats de l'MSE i FPE amb l'ordre definit.

Després de l'entrenament i la prova del model, es va examinar la seva qualitat. Es van realitzar alguns càlculs per conèixer l'error del model, és a dir, la precisió respecte al senyal original. Per tant, es va calcular la diferència entre el senyal predit i l'original, així com l'error mitjà quadràtic (MSE) i l'error de predicció final (FPE).



**Fig. 48.** Predicció a un horitzó de 60 passos vs el de 120. Dades EMG.



**Fig. 49.** Predicció a un horitzó de 60 passos vs el de 120. Dades EEG.

#### 4.5 Model ARX 2 entrades

Per comparar els resultats obtinguts i comprovar la hipòtesi de com afecten els dos senyals envers el funcionament del BIS, es va provar un altre model ARX amb 2 entrades i 1 sortida, essent els senyals EEG i EMG l'entrada i el senyal BIS la sortida.

En determinar els ordres del model, ja que hi havia dues entrades, els  $n_b$  i  $n_k$  eren diferents de  $n_a$ . Hi havia 2 valors que representaven les 2 entrades diferents que apareixien a les 2 funcions de transferència i els 2 retards. Hi havia dos valors de  $n_k$ , i no de  $n_a$ , perquè només hi havia una sortida i  $n_k$  depèn tant de l'entrada com de la sortida.

D'igual manera que amb les prediccions d'una sola entrada, el model ARX es va calcular a diferents horitzons, 1, 10, 60 i 120, així com el MSE i el FPE. Es va constatar que els valors eren pràcticament iguals entre ells i presentaven diferències mínimes, tot i les variacions de les ordres utilitzades.

EMG i EEG			
Ordre	Horitzó	MSE	FPE
[5][11][00]	1	0,0352	0,0353
	10	0,3519	0,3524
	60	2,1018	2,1045
	120	5,4674	5,4746

**Taula 9.** Resultats de l'MSE i FPE amb l'ordre definit.

## METODOLOGIA MODELS NO LINEALS

### 5.1 NNOE

Seguidament, s'explicarà el procediment del model no lineal NNOE.

El processament de dades inicial inclòs en les accions de: llegir dades, aplicar els filtres corresponents i la divisió d'aquestes en el grup d'ajust/entrenament i validació s'ha executat de la mateixa manera que s'ha fet amb el model lineal oe.

Arribat aquest punt s'ha definit la xarxa neuronal i l'ordre de model, que és el mateix definit a l'OE.

```
NetDef = ['HHH'; 'L--'];
nb=2;nf=3;nk=0;
NN=[nb nf nk];
```


Mitjançant el codi adjunt a l'Annex 10.5 es busca l'error mínim, que en aquest cas és 12,94:

```
iteration # 16 W = 1.294e+01
```

Una vegada realitzat el pas anterior, es busquen els resultats a 1 horitzó:


```
[yhat,NSSE]=nnvalid('nnoe',NetDef,NN,[P1],P2,sort_validacio',ent_validacio');
```

En el primer gràfic de la fig 50 es pot observar com la predicció segueix la dinàmica de la sortida, prediu de manera acceptable a línia basal. En el segon gràfic es pot veure l'error de predicció que oscil·la entre aproximadament un valor de [33 i -35], cosa que fa desconfiar en el model, ja que la variació de l'error és elevada.



**Fig. 50.** Resultats de la predicció de la funció 'nnvalid'.


En la figura 51 s'observa que el valor d'autocorrelació es manté a 0,75, valor que indica una forta correlació entre l'error de predicció. És útil per avaluar si hi ha alguna repetició, ja que es basa en la correlació d'un senyal amb ell mateix. En conseqüència, quan el valor és 1, significa que és idèntic, però baixarà a mesura que es desvii de si mateix. A més, mostra dues línies puntejades que representen el nivell significatiu i que es calculen fent 3 desviacions estàndard.



**Fig. 51.** Funció d'autocorrelació de la predicció de l'error.



A més, es gràfica un histograma dels errors de predicció en el qual veiem que el nombre més abundant en nombre de repeticions de l'error es troba entre aproximadament els valors [-1,5 i 7,5].




**Fig. 52.** Histograma dels errors de predicció.


Per acabar, s'aplica el 'kpredict' per canviar l'horitzó de predicció del model. S'aplica a 1, 10, 25, 50 i 100 passos.

```
Ypred1=kpredict('nnoe',NetDef,NN,1,[P1],[P2],sort_validacio',ent_validacio');
```


NOTA: Els gràfics es poden veure ampliat a l'apartat 10.7.55 dels Annexos.




**Fig. 53.** Predicció a 1 pas.




**Fig. 54.** Predicció a 10 passos.



**Fig. 55.** Predicció a 25 passos.



**Fig. 56.** Predicció a 50 passos.



**Fig. 57.** Predicció a 100 passos.



## 5.2 NNARX

En aquesta última secció, es desenvolupen els resultats obtinguts utilitzant la funció 'nnsysid' de Matlab. En primer lloc, es va comprovar que el model tenia el mateix funcionament que el lineal quan es modificaven les ordres. Això es deu al fet que les principals variacions dels resultats es reflectien quan s'alterava el paràmetre na, però nb i nk no. Així, quan es feia la modificació a nb, però na i nk restaven iguals, la diferència era petita.

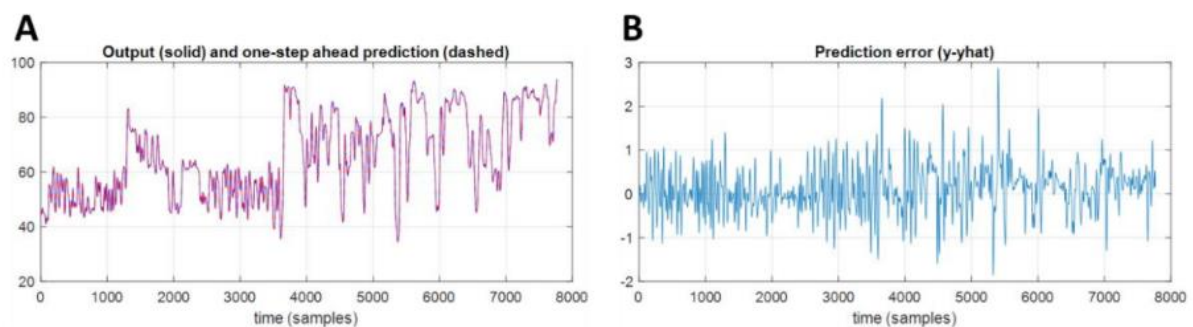
Com es va demostrar en els models lineals, no és necessari simular un gran nombre d'estructures diferents ni nivells alts. No obstant això, si el model té un gran nombre de neurones a l'estructura, serà més precís, però funcionarà més lentament, i si el model té una estructura petita, anirà més de pressa, però serà menys precís.

En conseqüència, es va realitzar una estructura amb 1 a 3 neurones. Tanmateix, malgrat que era un nombre petit de neurones, es va comprovar que tenia un rendiment lent. Les que van mostrar els millors resultats van tenir la següent estructura:

```
NetDef=['H'; 'L'];
NetDef=['HH'; 'L-'];
NetDef=['HHH'; 'L--'];
```

**Fig. 58.** Estructures de les neurones al model no lineal NNARX.

Pel que fa a la funció 'nvalid', es va comprovar els seus bons resultats, ja que prediu un pas més endavant, la qual cosa és important per avaluar la fiabilitat del NNARX.




**Fig. 59. A:** Sortida real vs sortida predita.

**B:** Error de predicció, valors no superiors a 3 ni inferiors a -2.

No obstant això, les variacions d'ordres o estructures, tots els models van mostrar els mateixos resultats en fer aquest gràfic de predicció d'un pas.

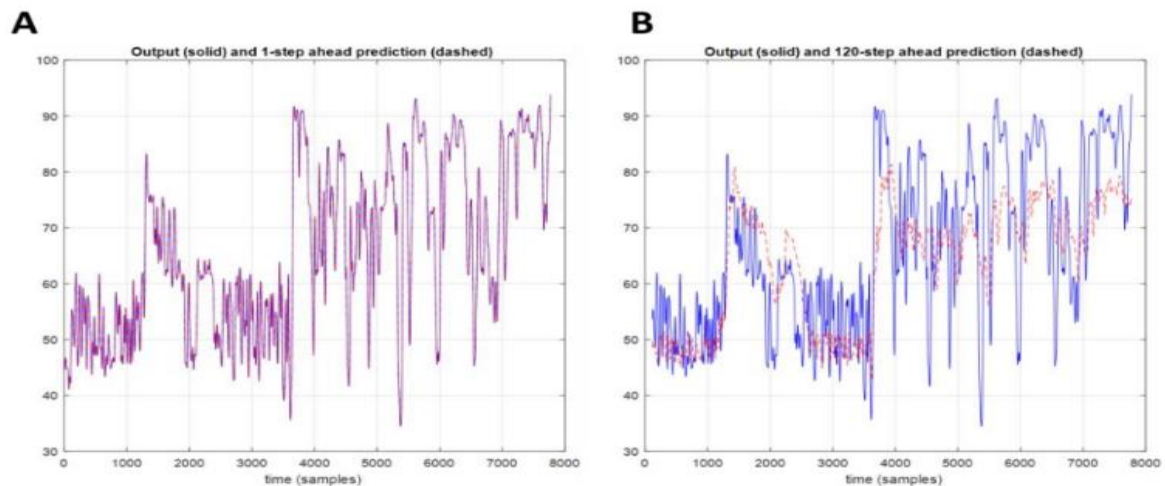
La funció d'autocorrelació va mostrar els resultats esperats, sense cap mena de repetició en els desfasaments, tot i que en algunes ordres hi havia un petit increment que semblava un intent de repetició.



**Fig. 60.** Funció d'autocorrelació a l'estructura [HHH, L--] amb un ordre [110].

Des d'una perspectiva estadística, el model realitzat en aquest projecte es basa en una simulació numèrica que prova el funcionament de diferents mètodes a partir d'un únic registre, que es basa en dades experimentals, encara que hi hagi més. Aquestes dades són vàlides, ja que provenen d'una col·lecció mèdica que conté la informació desitjada. En conseqüència, sempre s'obtidran els mateixos resultats. Per poder elaborar estadístiques, cal provar els models amb senyals diferents.

No obstant això, la funció 'nvalid' utilitzada per desenvolupar el model mostra un histograma que, tot i ser una predicció d'un pas, es pot entendre des d'un punt de vista estadístic, ajudant a conèixer el bon funcionament i la qualitat del model. Aquest histograma està correctament centrat a 0 en totes les combinacions i és simètric, formant una distribució normal que suggereix que el model fa prediccions generalment precises.



**Fig. 61.** Diferència al model NNARX amb un horitzó de predicció d'1 i 120.

A: Predicció a 1 pas NNARX.

B: Predicció a 120 passos NNARX.

Els resultats de la predicció en diferents horitzons van ser bons perquè van funcionar com s'esperava, empitjorant amb el temps, com fa el model ARX lineal. No obstant això, la velocitat d'execució del codi era més baixa i era necessari repetir l'execució més vegades per aconseguir les 300 iteracions quan es van provar els senyals EEG i els dos senyals.

Pel que fa al temps d'execució en el model NNARX, en provar d'executar la predicció amb un horitzó de 60 i 120 en el senyal EEG i en la combinació dels dos senyals, va durar més temps que en els altres casos, es va mesurar i va durar aproximadament 26 minuts. No obstant això, els resultats de desviació estàndard i mitjana van ser millors en el senyal EEG que en l'EMG, com va passar en els models lineals.

## DESENVOLUPAMENT DE LA SOLUCIÓ

Una vegada desenvolupada la metodologia i l'obtenció mitjançant tècniques d'identificació, un model amb estructura d'Output Error per a la relació entre el senyal EMG del pacient i l'índex de consciència BIS. S'ha pogut comprovar que els millors resultats d'identificació obtinguts corresponen a un model d'ordre 2 al numerador, d'ordre 3 al denominador i cap mostra de retard.

Cal destacar que per aconseguir els resultats s'han fet servir totes les dades disponibles del registre d'un pacient, des de la data d'inici del registre fins al punt que els elèctrodes van ser retirats.

Una vegada assolits els resultats preliminars, s'ha volgut analitzar si és més eficaç utilitzar una variable d'entrada o dues. A més, cal saber si es pot reduir el conjunt de dades experimentals necessari per assolir un bon ajust de les dades amb els resultats reals.

Si s'observa la taula 5 i 6 es poden veure els resultats de l'MSE i FPE, en funció del nombre de variables d'entrada. Els resultats no difereixen molt entre ambdues taules, bàsicament els resultats són molt semblants, per tant, es decideix fer servir només 1 entrada, ja que com els resultats no varien gaire és preferible fer servir només un vector de dades per simplificar la complexitat del model.

Com a conclusió en la comparativa entre el percentatge de dades més adequat per a emprar, s'ha de mencionar que amb l'1% de dades provistes el model no s'ajusta completament, però es pot veure com segueix sense problemes la tendència de les dades de validació. Es pot afirmar que se simula molt bé la línia basal, fet corroborat per una infermera de l'Hospital General de Catalunya (HGC). A més en el cas de fer servir el 100% de les dades es dona el mateix cas, la diferència és que el fit augmenta d'un 32% a un 43%, només incrementa en un 11%.

Una dada important que cal tenir en compte, és el temps de resposta del model en funció del percentatge aplicat.

Un 1% de dades fetes servir, aporta un valor ràpid que es pot fer servir per veure com afecta la medicació a la persona. S'agafen 155 dades que equivalen a 2min 35seg. Amb un 10% de dades es pot simular l'evolució als 26 min aproximadament i veure entre quins valors es pot trobar el BIS. Ja es tracten 1550 dades. I, amb el 100% dels valors, es pot conèixer el BIS exacte amb la tolerància d'error corresponent. Es fan servir 15500 dades i 4h aproximadament.

Cal definir un interval de confiança per saber concretament entre quins valors pot oscil·lar l'error de simulació. En l'histograma mostrat a la fig. 45 s'observa que en un 1% de dades usades l'error no marxa més enllà del 20%, d'igual manera que succeeix amb un percentatge del 100%.

Finalment, cal dir que amb 155 dades es pot ajustar un model, que en 2min i 35seg pot simular si la dosi administrada al pacient fa efecte o no. Aquest valor no serà el BIS exacte, però sí que serà una aproximació ràpida per saber l'estat del pacient. En aquest curt termini, es pot veure si la sedació fa efecte, si la dosi aplicada és molt baixa o si, per contra, és massa elevada.

Com a conclusió final del treball cal ressaltar que en aquest estudi concretament és més eficaç fer servir les dades EMG que no pas les d'EEG, així com és preferible fer servir 1 sola entrada al model en comptes de dues. També s'ha de mencionar que el model lineal OE ha sabut simular de manera més efectiva la línia basal del model, que no pas la predicció del model ARX o les estructures dels models no lineals. Per finalitzar, s'ha assolit l'objectiu final de simular amb èxit la línia basal del sistema, fet afirmat per una infermera de l'HGC, i a més s'ha pogut realitzar en un temps de 2 minuts i 35 segons. Per tant, amb aquest sistema es pot veure la reacció a 155 segons vista la reacció d'un pacient a la dosi aplicada.

Aquests resultats són rellevants perquè, poden ajudar a prevenir la sedació insuficient o excessiva del pacient només utilitzant un senyal, ja que el metge podrà saber com estan funcionant els medicaments, com el propofol, que tenen un efecte inferior a un minut, en el pacient.

## PLA DE TREBALL FINAL

En aquest pla de treball final es poden veure reflectides les incidències en el transcurs del treball.

### DIAGRAMA DE GANTT

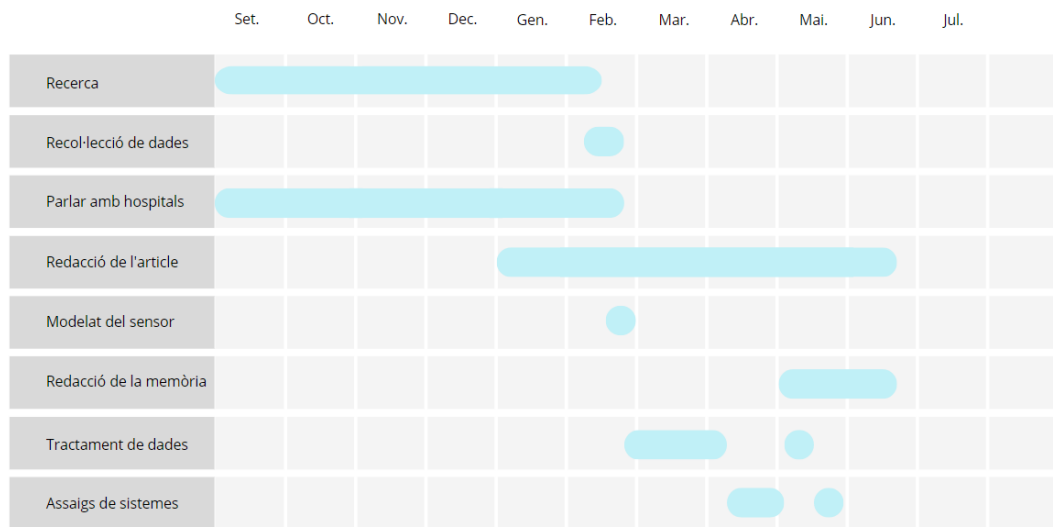


Fig. 62. Pla de treball final

### DIAGRAMA DE GANTT




Fig. 63. Pla de treball inicial.

- Recerca: es va allargar perquè encara no es disposava de les dades per començar a treballar en el projecte.
- Recol·lecció de dades: Finalment, amb una sola visita presencial a l'hospital es van obtenir les dades, però la negociació i la visita van ser prolongades fins a mitjans de febrer.
- Redacció de l'article: Segueix en curs perquè falten les conclusions per part de la infermera de l'Hospital General.
- Redacció de la memòria: El període s'ha vist escurçat, ja que el processament de les dades va generar problemes que feien incompatible la feina de la redacció amb la feina de codi.
- Tractament de dades: Van sorgir problemes amb els senyals. Es va dedicar cert temps al disseny de filtres que finalment no es va acabar implementant.
- Assaig de sistemes: Finalment, es va dividir en dos grups, l'oe i l'nnoe. En acabar l'oe es va seguir amb l'nnoe.

## IMPLICACIONS SOCIALS

Com s'ha comentat al llarg de la memòria, aquest estudi té una gran implicació en l'àmbit social.

Totes les millores i implementacions mèdiques tenen repercussió en la qualitat de vida dels pacients. Un clar exemple són els robots que estan a quiròfan, gràcies a ells el/la cirurgià/ana pot operar evitant el tremolor de les extremitats, fent així més difícil errar en les operacions per aquest motiu.

D'igual manera que en el cas anterior, l'enginyeria té una forta repercussió en l'àmbit sanitari i aquest projecte pot ajudar a alleugerir el mal tràngol que suposa estar en cures pal·liatives, tant com a pacient o com a familiar.

## FUTURA IMPLEMENTACIÓ

Els passos futurs que hi ha per aquest estudi són implementar-ho en un dispositiu físic per a poder realitzar proves clíniques. És una millora en l'àmbit mèdic que pot ajudar molt als pacients i a les famílies que es troben en la casuística de les cures pal·liatives.

Com s'ha mencionat anteriorment en l'estudi, cal més recerca i estudi en aquest àmbit, pel fet que el tema mèdic és molt sensible i cal anar amb peus de plom en les conclusions que es duen a terme.

A més, per treballar amb més precisió el senyal EMG del pacient i evitar el soroll que provoca distorsió en el seu processament, cal implementar filtres que ajudin a eliminar les interferències provocades pels altres aparells de la sala.

Per acabar també cal dissenyar un bon prototip de diadema amb els elèctrodes i intentar que aquesta sigui més assequible al mercat, per tal que la implementació a cada pacient pugui ser més efectiva encara.

## BIBLIOGRAFIA CONSULTADA

1. E. K. Schildmann, J. Schildmann, and I. Kieseewetter, "Medication and monitoring in palliative sedation therapy: a systematic review and quality assessment of published guidelines," *J. Pain Symptom Manage.*, vol. 49, no. 4, pp. 734–746, Apr. 2015, doi: 10.1016/J.JPAINSYMMAN.2014.08.013.
2. A.-M. Krooupa, B. Vivat, S. Mckeever, E. Marcus, J. Sawyer, and P. Stone, "Identification and evaluation of observational measures for the assessment and/or monitoring of level of consciousness in adult palliative care patients: A systematic review for I-CAN-CARE," *Palliat. Med.*, vol. 34, no. 1, pp. 83–113, 2020, doi: 10.1177/0269216319871666.
3. A. M. Krooupa et al., "Do palliative care patients and relatives think it would be acceptable to use Bispectral index (BIS) technology to monitor palliative care patients' levels of consciousness? A qualitative exploration with interviews and focus groups for the I-CAN-CARE research programme," *BMC Palliat. Care*, vol. 21, no. 1, Dec. 2022, doi: 10.1186/S12904-022-00949- 352 W.
4. M. A. Vidal and L. M. Torres, "In memoriam Cicely Saunders, fundadora de los Cuidados Paliativos," *Rev. la Soc. Española del Dolor*, vol. 13, no. 3, pp. 143–144, 2006, Accessed: Feb. 07, 2023. [Online]. Available: [https://scielo.isciii.es/scielo.php?script=sci\\_arttext&pid=S1134-80462006000300001&lng=es&nrm=iso&tlng=es](https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1134-80462006000300001&lng=es&nrm=iso&tlng=es).
5. P. M. Ignacia del Río and D. Alejandra Palma, "CUIDADOS PALIATIVOS: HISTORIA Y DESARROLLO," Accessed: Feb. 07, 2023. [Online]. Available: <http://www.stchristophers.org.uk>.
6. J. L. Stone and J. R. Hughes, "Early history of electroencephalography and establishment of the american clinical neurophysiology society," *J. Clin. Neurophysiol.*, vol. 30, no. 1, pp. 28–44, Feb. 2013, doi: 10.1097/WNP.0b013e31827edb2d.
7. Institut d'Estudis Catalans - Diec2 (n.d.). Retrieved June 8, 2023, from <https://dlc.iec.cat/Results?DecEntradaText=electroencefal%C3%B2graf&#38;AllInfoMorf=False&#38;OperEntrada=0&#38;OperDef=0&#38;OperEx=0&#38;OperSubEntrada=0&#38;OperAreaTematica=0&#38;InfoMorfType=0&#38;OperCatGram=False&#38;AccentSen=False&#38;CurrentPage=0&#38;refineSearch=0&#38;Actualitzacions=False</div>>
8. J. M. LeBlanc, J. F. Dasta, and S. L. Kane-Gill, "Role of the bispectral index in sedation monitoring in the ICU," *Ann. Pharmacother.*, vol. 40, no. 3, pp. 490–500, Mar. 2006, doi: 10.1345/APH.1E491.
9. José Mauel González Cava. «Monitorización de la información del electroencefalograma en el proceso anestésico» [en línia]. Treball de final de grau, Universitat de la Laguna, Escola Superior d'enginyeria i tecnologia, 2014. [Consulta: 5 de maig 2023]. Disponible a: [https://drive.google.com/drive/u/0/folders/1IZTmH\\_2KUoZj-RLPXMwfBknQy1q2W08p](https://drive.google.com/drive/u/0/folders/1IZTmH_2KUoZj-RLPXMwfBknQy1q2W08p)
10. Bitbrain, E. equipo de (2022) *Localización de Electroodos del Eeg: Layout Fijo vs. variable*, Bitbrain. Available at: <https://www.bitbrain.com/es/blog/colocacion-electrodos-eeg> (Accessed: 12 June 2023).
11. C. S. Nayak and A. C. Anilkumar, "EEG Normal Waveforms," *StatPearls*, pp. 1–6, Jul. 2022, Accessed: Feb. 08, 2023. [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK539805/>.
12. EL MODELO NEURONAL DE McCULLOCH Y PITTS Interpretación Comparativa del Modelo (n.d.). Retrieved June 2, 2023, from [https://www.researchgate.net/publication/343141076\\_EL\\_MODELO\\_NEURONAL\\_DE\\_McCULLOCH\\_Y\\_PITTS\\_Interpretacion\\_Comparativa\\_del\\_Modelo</div>](https://www.researchgate.net/publication/343141076_EL_MODELO_NEURONAL_DE_McCULLOCH_Y_PITTS_Interpretacion_Comparativa_del_Modelo</div>)



13. *DISSENY I DESENVOLUPAMENT DE XARXES NEURONALS ARTIFICIALS* (*n.d.*). Retrieved June 10, 2023, from [https://premisrecerca.uvic.cat/sites/default/files/webform/cae86b16fca7fdb38f85cd89b61e87f54427d0f\\_Xarxes%20Neuronals%20Artificials.pdf](https://premisrecerca.uvic.cat/sites/default/files/webform/cae86b16fca7fdb38f85cd89b61e87f54427d0f_Xarxes%20Neuronals%20Artificials.pdf)
14. Covidien, “Operator’s Manual.”
15. S. Mathur, J. Patel, S. Goldstein, and A. Jain, “Bispectral Index,” *J. Exp. Clin. Med.*, vol. 39, no. 2, pp. 587–588, Sep. 2022, doi: 10.52142/omujecm.39.2.60.
16. M. L. Riess, U. A. Graefe, C. Goeters, H. Van Aken, and H. G. Bone, “Sedation assessment in critically ill patients with bispectral index,” *Eur. J. Anaesthesiol.*, vol. 19, no. 1, p. 18, Jan. 2002, doi: 10.1017/S0265021502000030.
17. “Bispectral Index™ (BISTM) Monitoring System | Medtronic.” <https://www.medtronic.com/covidien/en-us/products/brain-monitoring/bis-monitoring-system.html> (accessed Feb. 24, 2023).
18. P. Pandharipande, J. Jackson, and E. W. Ely, “Delirium, Sleep, and Mental Health Disturbances in Critical Illness,” *Crit. Care Med. Princ. Diagnosis Manag. Adult*, pp. 1531–1546, 2008, doi: 10.1016/B978-032304841-5.50075-3.
19. S. Six et al., “Attitudes of Professional Caregivers and Family Members Regarding the Use of Monitoring Devices to Improve Assessments of Pain and Discomfort During Continuous Sedation Until Death,” *J. Pain Symptom Manage.*, vol. 60, no. 2, pp. 390–399, Aug. 2020, doi: 10.1016/J.JPAINSYMMAN.2020.02.015.
20. T. Brinkkemper, A. M. Van Norel, K. M. Szadek, S. A. Loer, W. W. A. Zuurmond, and R. S. G. M. Perez, “The use of observational scales to monitor symptom control and depth of sedation in patients requiring palliative sedation: A systematic review,” <http://dx.doi.org/10.1177/0269216311425421>, vol. 27, no. 1, pp. 54–67, Nov. 2011, doi: 10.1177/0269216311425421.
21. C. L. Tasaka, J. J. Duby, K. Pandya, M. D. Wilson, and K. A. Hardin, “Inadequate Sedation During Therapeutic Paralysis: Use of Bispectral Index in Critically Ill Patients,” *Drugs - Real World Outcomes*, vol. 3, no. 2, pp. 201–208, Jun. 2016, doi: 10.1007/S40801-016-0076-3.
22. E. Monreal-Carrillo, S. Allende-Pérez, D. Hui, M. F. García-Salamanca, E. Bruera, and E. Verástegui, “Bispectral Index monitoring in cancer patients undergoing palliative sedation: a preliminary report,” *Support. Care Cancer*, vol. 25, no. 10, pp. 388 3143–3149, Oct. 2017, doi: 10.1007/S00520-017-3722-8.
23. R. J. Hamill-Ruth and M. L. Marohn, “Evaluation of pain in the critically ill patient,” *Crit. Care Clin.*, vol. 15, no. 1, pp. 35–54, 1999, doi: 10.1016/S0749-0704(05)70038-5.
24. D. M. Olson, S. M. Chioffi, G. E. Macy, L. G. Meek, and H. A. Cook, “Potential Benefits of Bispectral Index Monitoring in Critical Care A Case Study,” *Crit. Care Nurse*, vol. 23, no. 4, pp. 45–52, Aug. 2003, doi: 10.4037/CCN2003.23.4.45.
25. T. Brinkkemper, A. M. Van Norel, K. M. Szadek, S. A. Loer, W. W. A. Zuurmond, and R. S. G. M. Perez, “The use of observational scales to monitor symptom control and depth of sedation in patients requiring palliative sedation: a systematic review,” *Palliat. Med.*, vol. 27, no. 1, pp. 54–67, Jan. 2013, doi: 10.1177/0269216311425421.

26. M. Barbato, G. Barclay, J. Potter, and W. Yeo, "Breakthrough Medication in Unresponsive Palliative Care Patients: Indications, Practice, and Efficacy," *J. Pain Symptom Manage.*, vol. 56, no. 6, pp. 944–950, Dec. 2018, doi: 10.1016/J.JPAINSYMMAN.2018.08.020.
27. A. D. Masman et al., "Bispectral Index Monitoring in Terminally Ill Patients: A Validation Study," *J. Pain Symptom Manage.*, vol. 52, no. 2, pp. 212–220.e3, Aug. 2016, doi: 10.1016/J.JPAINSYMMAN.2016.01.011.
28. P. H. Tonner, C. Wei, B. Bein, N. Weiler, A. Paris, and J. Scholz, "Comparison of two bispectral index algorithms in monitoring sedation in postoperative intensive care patients," *Crit. Care Med.*, vol. 33, no. 3, pp. 580–584, Mar. 2005, doi: 10.1097/01.CCM.0000156291.04287.7F.
29. J. K. Bell, H. U. Laasch, L. Wilbraham, R. E. England, J. A. Morris, and D. F. Martin, "Bispectral index monitoring for conscious sedation in intervention: Better, safer, faster," *Clin. Radiol.*, vol. 59, no. 12, pp. 1106–1113, 2004, doi: 10.1016/j.crad.2004.04.008.
30. Ljung\_L\_System\_Identification\_Theory\_for\_User-ed2
31. Apunts de l'assignatura Modelització de sistemes dinàmics 1 i 2.
32. Nørgaard, M. (n.d.). *Neural Network Based System Identification*
33. S. Tech Intl, "Medtronic BIS Complete 4 Channel Monitor - BIS Monitors." <https://www.somatechnology.com/BISMonitors/Medtronic-BIS-Complete-4-Channel-Monitor.aspx> (accessed Feb. 13, 2023).
34. M. Barbato, "Bispectral Index Monitoring in Unconscious Palliative Care Patients," <https://doi.org/10.1177/082585970101700206>, vol. 17, no. 2, pp. 102–107, Apr. 2019, doi: 10.1177/082585970101700206.
35. S. Arumugam et al., "Delirium in the Intensive Care Unit," *J. Emerg. Trauma. Shock*, vol. 10, no. 1, p. 37, Jan. 2017, doi: 10.4103/0974-2700.199520.
36. Identificación con Modelos Discretos para Sistemas Lineales: Modelo Matemático y Aplicaciones – Dialnet Retrieved June 5, 2023, from <https://dialnet.unirioja.es/servlet/articulo?codigo=4797338>
37. Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R. M., & Alonso, M. T. (2009). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas *Basic techniques of electroencephalography: principles and clinical applications*.
38. Monitor completo BIS™
39. Kailath, T., Anderson, E., Anderson, M., Astrljm, M., Basseville, W., Boyd, N., Dickinson Gardner Goodwin, B., Gray, S., Grewal, D., Haykin Haykin, A., Jain Jamshidi, ed, Johansson Johnson Kailath Kumar, S., Kung Kung Kung, V., Kwakemaak, E., Landau Ljung Ljung, S., Macovski Melsa, G., Middleton, S., Narendra, G., Porat Rugh Sastry, A., ... Spilker Williams, S. (n.d.). *Prentice Hall Information and System Sciences Series*
40. Garbiñe De Miguel Ansó. «Desarrollo de un sistema de gestor de alarmas basado en cardiotocogramas (CTG) para la asistencia al parto» [en línia]. Treball de final de grau, UPC, Escola Superior d'Enginyeries Industrial, Aeroespacial i Audiovisual de Terrassa, 2016. [Consulta: 5 de maig 2023]. Disponible a: <https://upcommons.upc.edu/handle/2117/107496>
41. José Mauel González Cava. «Monitorización de la información del electroencefalograma en el proceso anestésico» [en línia]. Treball de final de grau, Universitat de la Laguna, Escola Superior



- d'enginyeria i tecnologia, 2014. [Consulta: 5 de maig 2023]. Disponible a: [https://drive.google.com/drive/u/0/folders/1IZTmH\\_2KUoZj-RLPXMwfBknQy1q2W08p](https://drive.google.com/drive/u/0/folders/1IZTmH_2KUoZj-RLPXMwfBknQy1q2W08p)
42. Ana de la Torre García. «*Proyecto de implementación de un sistema de bajo coste y código abierto para estimación del nivel de consciencia*» [en línia]. Treball de final de grau, Universitat Politècnica de València, Facultat d'enginyeria biomèdica, 2021. [Consulta: 5 de maig 2023]. Disponible a: [https://drive.google.com/drive/u/0/folders/1IZTmH\\_2KUoZj-RLPXMwfBknQy1q2W08p](https://drive.google.com/drive/u/0/folders/1IZTmH_2KUoZj-RLPXMwfBknQy1q2W08p)
43. Andrea Navarro i López. *Estudi sobre les xarxes neuronals artificials* [en línia]. Treball de final de grau, Universitat de Barcelona, Facultat de Matemàtiques, 2016. [Consulta: 5 de maig 2023]. Disponible a: <https://diposit.ub.edu/dspace/bitstream/2445/98246/3/memoria.pdf>
44. Ferran Noguera Vall. *Compresió de Xarxes Neuronals artificials* [en línia]. Treball de final de grau, UPC, Facultat d'Informàtica de Barcelona, 2019. [Consulta: 5 de maig 2023]. Disponible a: <https://upcommons.upc.edu/bitstream/handle/2117/133053/136885.pdf?sequence=1&isAllowed=y>
45. Carlos Arturo Alva Coras. «*Procesamiento de señales de electromiografía superficial para la detección de movimiento de dos dedos de la mano*» [en línia]. Treball de final de grau, Universitat Ricardo Palma, Facultat d'Enginyeria Electrònica, 2012. [Consulta: 5 de maig 2023]. Disponible a: [https://repositorio.urp.edu.pe/bitstream/handle/20.500.14138/416/Alva\\_ca.pdf?sequence=1&isAllowed=y](https://repositorio.urp.edu.pe/bitstream/handle/20.500.14138/416/Alva_ca.pdf?sequence=1&isAllowed=y)
46. Carlota Lacasa Vela. «*A new based-model BIS Index study for awareness monitoring during palliative sedation*» [en línia]. Treball de final de grau, Universitat Internacional de Catalunya, Facultat de Medicina i Ciències de la Salut, 2023.

## ANNEXOS

### 10.1 Codi OE EMG

En el codi següent es troben totes línies necessàries per generar un model lineal oe. En primera instància es determina en quina localització es troben les dades per a poder carregar-les posteriorment. Una vegada determinada la localització es procedeix a llegir les dades dels senyals i a graficar-los mitjançant un 'plot'.

Tan bon punt s'han visualitzat les dades, comença la programació del model lineal oe. Primer es decideix amb quines dades (EMG o EEG) és més eficaç treballar mitjançant una correlació normalitzada. Després es preparen els vectors de dades d'ajust i de validació, als quals posteriorment se'ls aplicarà una resposta impulsional i una resposta a un graó.

Finalment, es troben els diferents models oe que mostraran els valors d'mse i fpe a la zona anomenada 'Workspace' de Matlab.

Netejar la línia de comandes i les dades

```
%%
clc;
clear all;
```

Definir on es troben les dades

```
%% Data folder name
DataFolderName='Dades EEG_VH';
%File name
FileName='L01311314';

%Define data file path
DataFilePath=[pwd filesep DataFolderName filesep FileName];

%Acces data folder
cd(DataFilePath);

%Acces to .spa data
fid=fopen([FileName '.spa'],'rt');
c=textscan(fid, repmat('%s',1,54), 'Delimiter','|', 'Headerlines',2);
Hora_Data=c{1};
fclose(fid);
```

Llegir i graficar els senyals

```
%% Read BIS signal
BIS=[cellfun(@(x)str2double(x),c{12}) ...
cellfun(@(x)str2double(x),c{26}) ...
cellfun(@(x)str2double(x),c{40})];
BIS(:,2:3)=[];

[pos]=find(BIS==-3276.8);
BIS(pos)=NaN;
[pos1]=find(BIS==0);
BIS(pos1)=NaN;
% Filtre BIS
%Gaussian filter
Window= 30;
BISfiltrat = smoothdata(BIS,"gaussian",Window);

%% Read EEG signal
%Acces to .spa data
fid=fopen([FileName '.r2a'],'rb');
```

```

%EEG signal
EEG=fread(fid,[4 inf],'int16');
fclose(fid);
%convert into microvolts by 0.0511 uV/step scale factor
EEG_uV=EEG*(1675.42688/32767);
EEGbo=mean(EEG_uV,2);
%% Filtre EEG
W=200;
EEGfiltrat=smoothdata(EEGbo,"gaussian",W);

%% Read EMG signal
EMG=cellfun(@(x)str2double(x),c{44});
[pos2]=find(EMG==-327.7);
EMG(pos2)=NaN;
[pos3]=find(EMG==0);
EMG(pos3)=NaN;
%% Filtre EMG
% %Gaussian filter
Window=30;
EMGfiltrat=smoothdata(EMG,"gaussian",Window);

stdEMG=std(EMGfiltrat);
[trobpos]=find(EMGfiltrat(1)<-10*stdEMG);
EMGfiltrat(trobpos)=NaN;

%% PERIODE DE MOSTREIG
N=length(EMG);
Ts=length(Hora_Data)/length(EMG); %diff entre 1r i ult Hora_Data
fs=1/Ts;
temps=0:Ts:(N-1)*Ts;

%% Plots
figure(1);
plot(BIS,'Color', "#A2142F",'LineWidth',1.5);
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal BIS Original');
legend('BIS Original');

figure(2);
hold on
plot(BIS,'Color', "#A2142F",'LineWidth',1.5);
plot(BISfiltrat,'Color', "#0072BD",'LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal BIS vs BIS Filtrat');
legend('BIS','BIS Filtrat');

figure(3);
plot(EMG,'color',"#7E2F8E",'LineWidth',1);
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal EMG Original');
legend('EMG Original');

```

```

figure(4);
hold on
plot(EMG, 'color', "#7E2F8E", 'LineWidth', 1.5);
%set((refline([0 stdEMG])), 'color', "#77AC30");
%set((refline([0 -6*stdEMG])), 'color', 'r');
plot(EMGfiltrat, 'color', '[1 0.5 0]', 'LineWidth', 1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal EMG vs EMG Filtrat');
legend('Senyal EMG', 'Desviació estàndard EMG', '-6 vegades la desviació estàndard EMG', 'EMG filtrat');

figure(5);
subplot(3,1,1);
plot(EMGfiltrat, 'color', "#7E2F8E", 'LineWidth', 1.5)
title('Senyal EMG');
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
subplot(3,1,2);
plot(BISfiltrat, 'Color', "#A2142F", 'LineWidth', 1.5)
title('Senyal BIS');
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
subplot(3,1,3);
plot(EEGfiltrat, 'Color', "#77AC30", 'LineWidth', 1.5)
title('Senyal EEG');
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;

```

#### Correlació normalitzada entre senyals

```

%% Correlació normalitzada entre senyals
[c, lags] = xcorr(EMGfiltrat-mean(EMGfiltrat), BISfiltrat-mean(BISfiltrat), 'normalized');
figure(6);
stem(lags, c);
title('Correlació entre el senyal EMG i el BIS');
xlabel('Retard temporal [seg]')
ylabel('Similitud [tant per 1]')
[c1, lags1] = xcorr(EEGfiltrat(1:15536)-mean(EEGfiltrat(1:15536)), BISfiltrat-mean(BISfiltrat), 'normalized');
figure(7);
stem(lags1, c1);
title('Correlació entre el senyal EEG i el BIS');
xlabel('Retard temporal [seg]')
ylabel('Similitud [tant per 1]')

```

#### Divisió del senyal en dades d'ajust i de validació

```

%% Divisió del senyal en dades d'entrenament i dades de validació
ent_entrenament = EMGfiltrat(1:7768,:);
ent_validacio = EMGfiltrat(7769:15536,:);
sort_entrenament = BISfiltrat(1:7768,1);
sort_validacio = BISfiltrat(7769:15536,1);

figure(8);

```

```
subplot(2,1,1)
hold on
plot(EMGfiltrat,'color','#7E2F8E','LineWidth',1.5);
plot(ent_entrenament,'color','#77AC30','LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal Entrada (EMG)');
legend('Dades Validació','Dades Entrenament');

subplot(2,1,2)
hold on
plot(BISfiltrat,'color',[1 0.5 0],'LineWidth',1.5);
plot(sort_entrenament,'color','#4DBEEE','LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal Sortida (BIS)');
legend('Dades Validació','Dades Entrenament');
```

Resposta impulsional i resposta a un graó

```
%% TEMPS
Nval=length(ent_validacio);
tempsval=0:Ts:(Nval-1)*Ts;
T=transpose(tempsval);
d=iddata(sort_entrenament,ent_entrenament,Ts);

figure(9)
ir=cra(d,20);
xlabel 'Nº Mostra'
ylabel 'Amplitud'

sr=cumsum(ir);
figure(10)
plot(sr)
xlabel 'Nº Mostra'
ylabel 'Amplitud'
title 'Resposta a un graó'
```

Models OE de diferents ordres

```
%% OE 120
%Transference function calculation
GdeY120=oe(d,[1 2 0]);
GdeY120.Ts=Ts;
%Simulation
ysim120=lsim(GdeY120,ent_validacio,T);
%ERROR
error120=sort_validacio-ysim120;
%MSE
mse120=GdeY120.Report.Fit.MSE;
%FPE
fpe120=GdeY120.Report.Fit.FPE;
%Plot
figure(11)
subplot(2,2,1)
compare(d,GdeY120)

%% OE 130
```

```

    %Transference function calculation
    GdeY130=oe(d,[1 3 0]);
    GdeY130.Ts=Ts;
    %Simulation
    ysim130=lsim(GdeY130,ent_validacio,T);
    %ERROR
    error130=sort_validacio-ysim130;
    %MSE
    mse130=GdeY130.Report.Fit.MSE;
    %FPE
    fpe130=GdeY130.Report.Fit.FPE;
    %Plot
    subplot(2,2,2)
    compare(d,GdeY130)
%% OE 140
    %Transference function calculation
    GdeY140=oe(d,[1 4 0]);
    GdeY140.Ts=Ts;
    %Simulation
    ysim140=lsim(GdeY140,ent_validacio,T);
    %ERROR
    error140=sort_validacio-ysim140;
    %MSE
    mse140=GdeY140.Report.Fit.MSE;
    %FPE
    fpe140=GdeY140.Report.Fit.FPE;
    %Plot
    subplot(2,2,3)
    compare(d,GdeY140)

%% OE 150
    %Transference function calculation
    GdeY150=oe(d,[1 5 0]);
    GdeY150.Ts=Ts;
    %Simulation
    ysim150=lsim(GdeY150,ent_validacio,T);
    %ERROR
    error150=sort_validacio-ysim150;
    %MSE
    mse150=GdeY150.Report.Fit.MSE;
    %FPE
    fpe150=GdeY150.Report.Fit.FPE;
    %Plot
    subplot(2,2,4)
    compare(d,GdeY150)

%% OE 220
    %Transference function calculation
    GdeY220=oe(d,[2 2 0]);
    GdeY220.Ts=Ts;
    %Simulation
    ysim220=lsim(GdeY220,ent_validacio,T);
    %ERROR
    error220=sort_validacio-ysim220;
    %MSE
    mse220=GdeY220.Report.Fit.MSE;
    %FPE
    fpe220=GdeY220.Report.Fit.FPE;
    %Plot

```

```

figure(12)
subplot(2,2,1)
compare(d,GdeY220)

%% OE 230
    %Transference function calculation
GdeY230=oe(d,[2 3 0]);
GdeY230.Ts=Ts;
    %Simulation
ysim230=lsim(GdeY230,ent_validacio,T);
    %ERROR
error230=sort_validacio-ysim230;
    %MSE
mse230=GdeY230.Report.Fit.MSE;
    %FPE
fpe230=GdeY230.Report.Fit.FPE;
%Plot
subplot(2,2,2)
compare(d,GdeY230)

%% OE 240
    %Transference function calculation
GdeY240=oe(d,[2 4 0]);
GdeY240.Ts=Ts;
    %Simulation
ysim240=lsim(GdeY240,ent_validacio,T);
    %ERROR
error240=sort_validacio-ysim240;
    %MSE
mse240=GdeY240.Report.Fit.MSE;
    %FPE
fpe240=GdeY240.Report.Fit.FPE;
%Plot
subplot(2,2,3)
compare(d,GdeY240)

%% OE 250
    %Transference function calculation
GdeY250=oe(d,[2 5 0]);
GdeY250.Ts=Ts;
    %Simulation
ysim250=lsim(GdeY250,ent_validacio,T);
    %ERROR
error250=sort_validacio-ysim250;
    %MSE
mse250=GdeY250.Report.Fit.MSE;
    %FPE
fpe250=GdeY250.Report.Fit.FPE;
%Plot
subplot(2,2,4)
compare(d,GdeY250)

%% OE 330
    %Transference function calculation
GdeY330=oe(d,[3 3 0]);
GdeY330.Ts=Ts;
    %Simulation
ysim330=lsim(GdeY330,ent_validacio,T);
    %ERROR

```

```

error330=sort_validacio-ysim330;
    %MSE
mse330=GdeY330.Report.Fit.MSE;
    %FPE
fpe330=GdeY330.Report.Fit.FPE;
%Plot
figure(13)
subplot(3,1,1)
compare(d,GdeY330)

%% OE 340
    %Transference function calculation
GdeY340=oe(d,[3 4 0]);
GdeY340.Ts=Ts;
    %Simulation
ysim340=lsim(GdeY340,ent_validacio,T);
    %ERROR
error340=sort_validacio-ysim340;
    %MSE
mse340=GdeY340.Report.Fit.MSE;
    %FPE
fpe340=GdeY340.Report.Fit.FPE;
%Plot
subplot(3,1,2)
compare(d,GdeY340)

%% OE 350
    % Transference function calculation
GdeY350=oe(d,[3 5 0]);
GdeY350.Ts=Ts;
    % Simulation
ysim350=lsim(GdeY350,ent_validacio,T);
    % ERROR
error350=sort_validacio-ysim350;
    % MSE
mse350=GdeY350.Report.Fit.MSE;
    % FPE
fpe350=GdeY350.Report.Fit.FPE;
% Plot
subplot(3,1,3)
compare(d,GdeY350)

%% OE 440
    %Transference function calculation
GdeY440=oe(d,[4 4 0]);
GdeY440.Ts=Ts;
    %Simulation
ysim440=lsim(GdeY440,ent_validacio,T);
    %ERROR
error440=sort_validacio-ysim440;
    %MSE
mse440=GdeY440.Report.Fit.MSE;
    %FPE
fpe440=GdeY440.Report.Fit.FPE;
%Plot
figure(14)
subplot(2,1,1)
compare(d,GdeY440)

```



```

%% OE 450
    %Transference function calculation
GdeY450=oe(d,[4 5 0]);
GdeY450.Ts=Ts;
    %Simulation
ysim450=lsim(GdeY450,ent_validacio,T);
    %ERROR
error450=sort_validacio-ysim450;
    %MSE
mse450=GdeY450.Report.Fit.MSE;
    %FPE
fpe450=GdeY450.Report.Fit.FPE;
%Plot
subplot(2,1,2)
compare(d,GdeY450)

%% OE 550
    % Transference function calculation
GdeY550=oe(d,[5 5 0]);
GdeY550.Ts=Ts;
    % Simulation
ysim550=lsim(GdeY550,ent_validacio,T);
    % ERROR
error550=sort_validacio-ysim550;
    % MSE
mse550=GdeY550.Report.Fit.MSE;
    % FPE
fpe550=GdeY550.Report.Fit.FPE;
% Plot
figure(15)
subplot(3,1,1)
compare(d,GdeY550)

%% OE 560
    %Transference function calculation
GdeY560=oe(d,[5 6 0]);
GdeY560.Ts=Ts;
    %Simulation
ysim560=lsim(GdeY560,ent_validacio,T);
    %ERROR
error560=sort_validacio-ysim560;
    %MSE
mse560=GdeY560.Report.Fit.MSE;
    %FPE
fpe560=GdeY560.Report.Fit.FPE;
%Plot
subplot(3,1,2)
compare(d,GdeY560)

%% OE 570
    %Transference function calculation
GdeY570=oe(d,[5 7 0]);
GdeY570.Ts=Ts;
    %Simulation
ysim570=lsim(GdeY570,ent_validacio,T);
    %ERROR
error570=sort_validacio-ysim570;
    %MSE
mse570=GdeY570.Report.Fit.MSE;

```

```

    %FPE
    fpe570=GdeY570.Report.Fit.FPE;
    %Plot
    subplot(3,1,3)
    compare(d,GdeY570)

%% OE 660
    %Transference function calculation
    GdeY660=oe(d,[6 6 0]);
    GdeY660.Ts=Ts;
    %Simulation
    ysim660=lsim(GdeY660,ent_validacio,T);
    %ERROR
    error660=sort_validacio-ysim660;
    %MSE
    mse660=GdeY660.Report.Fit.MSE;
    %FPE
    fpe660=GdeY660.Report.Fit.FPE;
    %Plot
    figure(16)
    subplot(3,1,1)
    compare(d,GdeY660)

%% OE 670
    %Transference function calculation
    GdeY670=oe(d,[6 7 0]);
    GdeY670.Ts=Ts;
    %Simulation
    ysim670=lsim(GdeY670,ent_validacio,T);
    %ERROR
    error670=sort_validacio-ysim670;
    %MSE
    mse670=GdeY670.Report.Fit.MSE;
    %FPE
    fpe670=GdeY670.Report.Fit.FPE;
    %Plot
    subplot(3,1,2)
    compare(d,GdeY670)

%% OE 770
    %Transference function calculation
    GdeY770=oe(d,[7 7 0]);
    GdeY770.Ts=Ts;
    %Simulation
    ysim770=lsim(GdeY770,ent_validacio,T);
    %ERROR
    error770=sort_validacio-ysim770;
    %MSE
    mse770=GdeY770.Report.Fit.MSE;
    %FPE
    fpe770=GdeY770.Report.Fit.FPE;
    %Plot
    subplot(3,1,3)
    compare(d,GdeY770)

```

## 10.2 Codi OE EEG

En el codi següent es troben totes línies necessàries per generar un model lineal oe. En primera instància es determina en quina localització es troben les dades per a poder carregar-les posteriorment. Una vegada determinada la localització es procedeix a llegir les dades dels senyals i a graficar-los mitjançant un 'plot'.

Tan bon punt s'han visualitzat les dades, comença la programació del model lineal oe. En aquest cas es decideix treballar amb les dades EEG i per tant, degut a el temps de mostreig, cal fer un 'resample' de les dades de sortida BIS. Després es preparen els vectors de dades d'ajust i de validació, als quals posteriorment se'ls aplicarà una resposta impulsional i una resposta a un graó.

Finalment, es troben els diferents models oe que mostraran els valors d'mse i fpe a la zona anomenada 'Workspace' de Matlab.

Netejar la línia de comandes i les dades

```
%%
clc;
clear all;
```

Definir on es troben les dades

```
%% Data folder name
DataFolderName='Dades EEG_VH';
%File name
FileName='L01311314';

%Define data file path
DataFilePath=[pwd filesep DataFolderName filesep FileName];

%Acces data folder
cd(DataFilePath);

%Acces to .spa data
fid=fopen([FileName '.spa'],'rt');
c=textscan(fid, repmat('%s',1,54), 'Delimiter','|', 'Headerlines',2);
Hora_Data=c{1};
fclose(fid);
```

Llegir i graficar els senyals

```
%% Read BIS signal
BIS=[cellfun(@(x)str2double(x),c{12}) ...
cellfun(@(x)str2double(x),c{26}) ...
cellfun(@(x)str2double(x),c{40})];
BIS(:,2:3)=[];

[pos]=find(BIS==-3276.8);
BIS(pos)=NaN;
[pos1]=find(BIS==0);
BIS(pos1)=NaN;
% Filtre BIS
%Gaussian filter
Window= 30;
BISfiltrat = smoothdata(BIS,"gaussian",Window);

% Read EEG signal
%Acces to .spa data
fid=fopen([FileName '.r2a'],'rb');
%EEG signal
EEG=fread(fid,[4 inf],'int16');
fclose(fid);
```

```

%convert into microvolts by 0.0511 uV/step scale factor
EEG_uV=EEG*(1675.42688/32767);
EEGbo=mean(EEG_uV,2);
%% Filtre EEG
W=200;
EEGfiltrat=smoothdata(EEGbo,"gaussian",W);

%% PERIODE DE MOSTREIG
N=length(EEG_uV);
Ts=length(Hora_Data)/length(EEG_uV); %diff entre 1r i ult Hora_Data
fs=1/Ts;
temps=0:Ts:(N-1)*Ts;

%% Plots
figure(1);
plot(BIS,'Color', '#A2142F','LineWidth',1.5);
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal BIS Original');
legend('BIS Original');

figure(2);
hold on
plot(BIS,'Color', '#A2142F','LineWidth',1.5);
plot(BISfiltrat,'Color', '#0072BD','LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal BIS vs BIS Filtrat');
legend('BIS','BIS Filtrat');

figure(3);
plot(temps,EEG_uV,'LineWidth',1);
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal EEG Original');
legend('CH1','CH2','CH3','CH4');

figure(4);
subplot(2,2,1)
plot(temps,EEG_uV(:,1),'LineWidth',1,'Color','#0072BD');
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal CH1 EEG');
legend('CH1');

subplot(2,2,2)
plot(temps,EEG_uV(:,2),'LineWidth',1,'Color','#D95319');
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal CH2 EEG');
legend('CH2');

subplot(2,2,3)

```

```

plot(temps, EEG_uV(:,3), 'LineWidth',1, 'Color', "#EDB120");
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal CH3 EEG');
legend('CH3');

subplot(2,2,4)
plot(temps, EEG_uV(:,4), 'LineWidth',1, 'Color', "#7E2F8E");
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal CH4 EEG');
legend('CH4');

figure(5);
plot(temps, EEGbo, 'color', "#17A589", 'LineWidth',1.5);
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal EEG');
legend('Mitja 4 canals EEG');

figure(6);
hold on
plot(temps, EEGbo, 'color', "#17A589", 'LineWidth',1.5);
plot(temps, EEGfiltrat, 'color', '[1 0.5 0]', 'LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud [uV]')
xlim([0 16000])
grid on;
title('Senyal EEG vs Senyal EEG filtrat');
legend('Mitja 4 canals EEG', 'EEG Filtrat');

```

Resample de les dades

```
sortida=resample(BISfiltrat(:,1),length(EEGfiltrat),length(BISfiltrat),0);
```

Divisió del senyal en dades d'ajust i de validació

```

% Divisió del senyal en senyal d'entrenament i validació
ent_entrenament = EEGfiltrat(1:496896,:);
ent_validacio = EEGfiltrat(496897:993792,:);
sort_entrenament= sortida(1:496896,:);
sort_validacio = sortida(496897:993792,:);

figure(7);
subplot(2,1,1)
hold on
plot(EEGfiltrat, 'color', '#039BE5', 'LineWidth',1.5);
plot(ent_entrenament, 'color', '#F06292', 'LineWidth',1.5);
hold off
xlabel('Nº Mostra [nº]')
ylabel('Amplitud [uV]')
grid on;
title('Senyal Entrada (EEG)');
legend('Dades Validació', 'Dades Entrenament');

subplot(2,1,2)
hold on
plot(sortida, 'color', '#F5B041', 'LineWidth',1.5);

```

```
plot(sort_entrenament, 'color', '#F4D03F', 'LineWidth', 1.5);
xlabel('Nº Mostra [nº]')
ylabel('Amplitud')
grid on;
title('Senyal Sortida (BIS)');
legend('Dades Validació', 'Dades Entrenament');
```

Resposta impulsional i resposta a un graó

```
%% TEMPS
Nval=length(ent_validacio);
tempsval=0:Ts:(Nval-1)*Ts;
T=transpose(tempsval);
d=iddata(sort_entrenament,ent_entrenament,Ts);

figure(8)
ir=cra(d,20);
xlabel 'Nº Mostra'
ylabel 'Amplitud'

sr=cumsum(ir);
figure(9)
plot(sr,"k")
xlabel 'Nº Mostra'
ylabel 'Amplitud'
title 'Resposta a un graó'
```

Models OE de diferents ordres

```
%% OE
%% OE 120
%Transference function calculation
GdeY120=oe(d,[1 2 0]);
GdeY120.Ts=Ts;
%Simulation
ysim120=lsim(GdeY120,ent_validacio,T);
%ERROR
error120=sort_validacio-ysim120;
%MSE
mse120=GdeY120.Report.Fit.MSE;
%FPE
fpe120=GdeY120.Report.Fit.FPE;
%Plot
figure(12)
subplot(2,2,1)
compare(d,GdeY120)

%% OE 130
%Transference function calculation
GdeY130=oe(d,[1 3 0]);
GdeY130.Ts=Ts;
%Simulation
ysim130=lsim(GdeY130,ent_validacio,T);
%ERROR
error130=sort_validacio-ysim130;
%MSE
mse130=GdeY130.Report.Fit.MSE;
%FPE
fpe130=GdeY130.Report.Fit.FPE;
%Plot
subplot(2,2,2)
```

```

compare(d,GdeY130)

%% OE 140
    %Transference function calculation
GdeY140=oe(d,[1 4 0]);
GdeY140.Ts=Ts;
    %Simulation
ysim140=lsim(GdeY140,ent_validacio,T);
    %ERROR
error140=sort_validacio-ysim140;
    %MSE
mse140=GdeY140.Report.Fit.MSE;
    %FPE
fpe140=GdeY140.Report.Fit.FPE;
%Plot
subplot(2,2,3)
compare(d,GdeY140)

%% OE 150
    %Transference function calculation
GdeY150=oe(d,[1 5 0]);
GdeY150.Ts=Ts;
    %Simulation
ysim150=lsim(GdeY150,ent_validacio,T);
    %ERROR
error150=sort_validacio-ysim150;
    %MSE
mse150=GdeY150.Report.Fit.MSE;
    %FPE
fpe150=GdeY150.Report.Fit.FPE;
%Plot
subplot(2,2,4)
compare(d,GdeY150)

%% OE 220
    %Transference function calculation
GdeY220=oe(d,[2 2 0]);
GdeY220.Ts=Ts;
    %Simulation
ysim220=lsim(GdeY220,ent_validacio,T);
    %ERROR
error220=sort_validacio-ysim220;
    %MSE
mse220=GdeY220.Report.Fit.MSE;
    %FPE
fpe220=GdeY220.Report.Fit.FPE;
%Plot
figure(13)
subplot(2,2,1)
compare(d,GdeY220)

%% OE 230
    %Transference function calculation
GdeY230=oe(d,[2 3 0]);
GdeY230.Ts=Ts;
    %Simulation
ysim230=lsim(GdeY230,ent_validacio,T);
    %ERROR
error230=sort_validacio-ysim230;

```



```

    %MSE
mse230=GdeY230.Report.Fit.MSE;
    %FPE
fpe230=GdeY230.Report.Fit.FPE;
%Plot
subplot(2,2,2)
compare(d,GdeY230)

%% OE 240
    %Transference function calculation
GdeY240=oe(d,[2 4 0]);
GdeY240.Ts=Ts;
    %Simulation
ysim240=lsim(GdeY240,ent_validacio,T);
    %ERROR
error240=sort_validacio-ysim240;
    %MSE
mse240=GdeY240.Report.Fit.MSE;
    %FPE
fpe240=GdeY240.Report.Fit.FPE;
%Plot
subplot(2,2,3)
compare(d,GdeY240)

%% OE 250
    %Transference function calculation
GdeY250=oe(d,[2 5 0]);
GdeY250.Ts=Ts;
    %Simulation
ysim250=lsim(GdeY250,ent_validacio,T);
    %ERROR
error250=sort_validacio-ysim250;
    %MSE
mse250=GdeY250.Report.Fit.MSE;
    %FPE
fpe250=GdeY250.Report.Fit.FPE;
%Plot
subplot(2,2,4)
compare(d,GdeY250)

%% OE 330
    %Transference function calculation
GdeY330=oe(d,[3 3 0]);
GdeY330.Ts=Ts;
    %Simulation
ysim330=lsim(GdeY330,ent_validacio,T);
    %ERROR
error330=sort_validacio-ysim330;
    %MSE
mse330=GdeY330.Report.Fit.MSE;
    %FPE
fpe330=GdeY330.Report.Fit.FPE;
%Plot
figure(14)
subplot(3,1,1)
compare(d,GdeY330)

%% OE 340
    %Transference function calculation

```

```
GdeY340=oe(d,[3 4 0]);
GdeY340.Ts=Ts;
    %Simulation
ysim340=lsim(GdeY340,ent_validacio,T);
    %ERROR
error340=sort_validacio-ysim340;
    %MSE
mse340=GdeY340.Report.Fit.MSE;
    %FPE
fpe340=GdeY340.Report.Fit.FPE;
%Plot
subplot(3,1,2)
compare(d,GdeY340)

%% OE 350
    %Transference function calculation
GdeY350=oe(d,[3 5 0]);
GdeY350.Ts=Ts;
    %Simulation
ysim350=lsim(GdeY350,ent_validacio,T);
    %ERROR
error350=sort_validacio-ysim350;
    %MSE
mse350=GdeY350.Report.Fit.MSE;
    %FPE
fpe350=GdeY350.Report.Fit.FPE;
%Plot
subplot(3,1,3)
compare(d,GdeY350)

%% OE 440
    %Transference function calculation
GdeY440=oe(d,[4 4 0]);
GdeY440.Ts=Ts;
    %Simulation
ysim440=lsim(GdeY440,ent_validacio,T);
    %ERROR
error440=sort_validacio-ysim440;
    %MSE
mse440=GdeY440.Report.Fit.MSE;
    %FPE
fpe440=GdeY440.Report.Fit.FPE;
%Plot
figure(15)
subplot(2,1,1)
compare(d,GdeY440)

%% OE 450
    %Transference function calculation
GdeY450=oe(d,[4 5 0]);
GdeY450.Ts=Ts;
    %Simulation
ysim450=lsim(GdeY450,ent_validacio,T);
    %ERROR
error450=sort_validacio-ysim450;
    %MSE
mse450=GdeY450.Report.Fit.MSE;
    %FPE
fpe450=GdeY450.Report.Fit.FPE;
%Plot
```

```

subplot(2,1,2)
compare(d,GdeY450)

%% OE 550
    %Transference function calculation
GdeY550=oe(d,[5 5 0]);
GdeY550.Ts=Ts;
    %Simulation
ysim550=lsim(GdeY550,ent_validacio,T);
    %ERROR
error550=sort_validacio-ysim550;
    %MSE
mse550=GdeY550.Report.Fit.MSE;
    %FPE
fpe550=GdeY550.Report.Fit.FPE;
%Plot
figure(16)
subplot(3,1,1)
compare(d,GdeY550)

%% OE 560
    %Transference function calculation
GdeY560=oe(d,[5 6 0]);
GdeY560.Ts=Ts;
    %Simulation
ysim560=lsim(GdeY560,ent_validacio,T);
    %ERROR
error560=sort_validacio-ysim560;
    %MSE
mse560=GdeY560.Report.Fit.MSE;
    %FPE
fpe560=GdeY560.Report.Fit.FPE;
%Plot
subplot(3,1,2)
compare(d,GdeY560)

%% OE 570
    %Transference function calculation
GdeY570=oe(d,[5 7 0]);
GdeY570.Ts=Ts;
    %Simulation
ysim570=lsim(GdeY570,ent_validacio,T);
    %ERROR
error570=sort_validacio-ysim570;
    %MSE
mse570=GdeY570.Report.Fit.MSE;
    %FPE
fpe570=GdeY570.Report.Fit.FPE;
%Plot
subplot(3,1,3)
compare(d,GdeY570)

%% OE 660
    %Transference function calculation
GdeY660=oe(d,[6 6 0]);
GdeY660.Ts=Ts;
    %Simulation
ysim660=lsim(GdeY660,ent_validacio,T);
    %ERROR

```

```

error660=sort_validacio-ysim660;
    %MSE
mse660=GdeY660.Report.Fit.MSE;
    %FPE
fpe660=GdeY660.Report.Fit.FPE;
%Plot
figure(17)
subplot(3,1,1)
compare(d,GdeY660)

%% OE 670
    %Transference function calculation
GdeY670=oe(d,[6 7 0]);
GdeY670.Ts=Ts;
    %Simulation
ysim670=lsim(GdeY670,ent_validacio,T);
    %ERROR
error670=sort_validacio-ysim670;
    %MSE
mse670=GdeY670.Report.Fit.MSE;
    %FPE
fpe670=GdeY670.Report.Fit.FPE;
%Plot
subplot(3,1,2)
compare(d,GdeY670)

%% OE 770
    %Transference function calculation
GdeY770=oe(d,[7 7 0]);
GdeY770.Ts=Ts;
    %Simulation
ysim770=lsim(GdeY770,ent_validacio,T);
    %ERROR
error770=sort_validacio-ysim770;
    %MSE
mse770=GdeY770.Report.Fit.MSE;
    %FPE
fpe770=GdeY770.Report.Fit.FPE;
%Plot
subplot(3,1,3)
compare(d,GdeY770)

```

### 10.3 Codi Mínim Conjunt de Dades

En el codi següent es troben totes línies necessàries per generar un model lineal oe amb el mínim conjunt de dades emprades. Com en els casos anteriors, el procediment és molt similar. En primera instància es determina en quina localització es troben les dades per a poder carregar-les posteriorment. Una vegada determinada la localització es procedeix a llegir les dades dels senyals i a graficar-los mitjançant un 'plot'.

Tan bon punt s'han visualitzat les dades, comença la programació del model lineal oe amb el mínim conjunt de dades. En aquest cas es decideix treballar amb les dades EMG, perquè s'ha vist mitjançant la correlació normalitzada anterior, que és més eficaç. Després es preparen els vectors de dades d'ajust i de validació, als quals posteriorment se'ls aplicarà el millor model oe escollit, concretament el 230.

Finalment, es van comparant els resultats obtinguts en funció de les dades utilitzades i s'extreuen les conclusions.

Netejar la línia de comandes i les dades

```
%%
clc;
clear all;
```

Definir on es troben les dades

```
%% Data folder name
DataFolderName='Dades EEG_VH';
%File name
FileName='L01311314';

%Define data file path
DataFilePath=[pwd filesep DataFolderName filesep FileName];

%Acces data folder
cd(DataFilePath);

%Acces to .spa data
fid=fopen([FileName '.spa'],'rt');
c=textscan(fid, repmat('%s',1,54), 'Delimiter', '|', 'Headerlines', 2);
Hora_Data=c{1};
fclose(fid);
```

Llegir i graficar els senyals

```
%% Read BIS signal
BIS=[cellfun(@(x)str2double(x),c{12}) ...
cellfun(@(x)str2double(x),c{26}) ...
cellfun(@(x)str2double(x),c{40})];
BIS(:,2:3)=[];

[pos]=find(BIS== -3276.8);
BIS(pos)=NaN;
[pos1]=find(BIS==0);
BIS(pos1)=NaN;
%% Filtre BIS
%Gaussian filter
Window= 30;
BISfiltrat = smoothdata(BIS,"gaussian",Window);

%% Read EEG signal
%Acces to .spa data
fid=fopen([FileName '.r2a'],'rb');
%EEG signal
EEG=fread(fid,[4 inf],'int16');
fclose(fid);
%convert into microvolts by 0.0511 uV/step scale factor
EEG_uV=EEG*(1675.42688/32767);
EEGbo=mean(EEG_uV,2);
%% Filtre EEG
W=200;
EEGfiltrat=smoothdata(EEGbo,"gaussian",W);

%% Read EMG signal
EMG=cellfun(@(x)str2double(x),c{44});
[pos2]=find(EMG== -327.7);
EMG(pos2)=NaN;
[pos3]=find(EMG==0);
EMG(pos3)=NaN;
%% Filtre EMG
% %Gaussian filter
```

```
Window=30;
EMGfiltrat=smoothdata(EMG,"gaussian",Window);

stdEMG=std(EMGfiltrat);
[trobpos]=find(EMGfiltrat(1)<-10*stdEMG);
EMGfiltrat(trobpos)=NaN;
```

Graficar

```
%% PERIODE DE MOSTREIG
N=length(EMG);
Ts=length(Hora_Data)/length(EMG); %diff entre 1r i ult Hora_Data
fs=1/Ts;
temps=0:Ts:(N-1)*Ts;

%%
%n=100;
percentatge=.1:.1:1;
valors=zeros(length(percentatge),2);
comptador=1;

for percentatge=.1:.1:1

figura=round(percentatge*100);

dadesEMG=EMGfiltrat(1:round(percentatge*length(EMGfiltrat)));
dadesBIS=BISfiltrat(1:round(percentatge*length(BISfiltrat)));

llegenda = sprintf('%g%% Dades EMG',percentatge*100);
llegenda2 = sprintf('%g%% Dades BIS', percentatge*100);

figure(figura);
subplot(2,1,1)
hold on
plot(temps,BISfiltrat,'Color', "#A2142F",'LineWidth',1.5,'DisplayName',llegenda);
plot(temps(1:length(dadesBIS)),dadesBIS,'Color', "#77AC30",'LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal BIS');
legend('100% Dades BIS',llegenda);

subplot(2,1,2)
hold on
plot(temps,EMGfiltrat,'Color', "#7E2F8E",'LineWidth',1.5,'DisplayName',llegenda2);
plot(temps(1:length(dadesEMG)),dadesEMG,'Color', '[1 0.5 0]','LineWidth',1.5);
hold off
xlabel('Temps [seg]')
ylabel('Amplitud')
grid on;
title('Senyal EMG');
legend('100% Dades EMG',llegenda2);
```

Divisió del senyal en dades d'ajust i de validació

```
%% Divisió del senyal en senyal d'entrenament i validació
%% DE DADES
ent_entrenament = EMGfiltrat(1:length(dadesEMG),:);
ent_validacio = EMGfiltrat(1:length(EMGfiltrat),:);
```

```
sort_entrenament = BISfiltrat(1:length(dadesBIS),:);
sort_validacio = BISfiltrat(1:length(BISfiltrat),:);

%% TEMPS
Nval=length(ent_validacio);
tempsval=0:Ts:(Nval-1)*Ts;
T=transpose(tempsval);
d=iddata(sort_entrenament,ent_entrenament,Ts);
```

Millor ordre per fer la comparativa

```
%% OE 230
    %Transference function calculation
GdeY230=oe(d,[2 3 0]);
GdeY230.Ts=Ts;
    %Simulation
ysim230=lsim(GdeY230,ent_validacio,T);
    %ERROR
error230=sort_validacio-ysim230;
    %MSE
%mse230=GdeY230.Report.Fit.MSE;
mse230=mse(error230);
    %FPE
%fpe230=GdeY230.Report.Fit.FPE;
%Plot
figure(figura+100)
compare(d,GdeY230)
    valors(comptador, 1) = round(percentatge*100);
    valors(comptador, 2) = mse230;
    %valors(comptador, 3) = fpe230;

    comptador=comptador+1;
end

compare([sort_validacio ent_validacio],GdeY230) %es 1% de dades, es fa amb el
break point
figure(301)
compare([sort_validacio ent_validacio],GdeY230)

fitdist(error230(40:end),'Normal');

figure(303)
plot(error230(40:end))
xlabel('Temps [seg]') %Dades utilitzades per a l'entrenament
ylabel('Percentatge de l''error [%]') %MSE calculat amb les dades de validació
completes
grid on
title('Error en funció del temps');
figure(304)
histogram(error230(40:end),'FaceColor', '#32FDC3');
xlabel('Percentatge de l''error [%]') %Dades utilitzades per a l'entrenament
ylabel('Nº vegades de l''error [nº]') %MSE calculat amb les dades de validació
completes
grid on
title('Histograma de l''error');

%valors(valors(:,2)>120,2)=NaN;
cont=0;
figure(300)
hold on
```

```
% plot(valors(:,1),valors(:,2),'--o','Linewidth',1.5,'Color','#BF3FF4")
plot(valors(:,1),valors(:,2)./min(valors(:,2)), 'Linewidth',1.5)
xlabel('Dades utilitzades [%]') %Dades utilitzades per a l'entrenament
ylabel('MSE Normalitzat') %MSE calculat amb les dades de validació completes
grid on;
title('MSE en funció del percentatge de dades utilitzades');
% ylim([70 120])
% for m = 1:length(valors(:,2))
%
%     text(valors(10+cont, 1),valors(10+cont,2), sprintf('%0.2f',val-
ors(10+cont,2)), 'VerticalAlignment','top','HorizontalAlignment','center','Font-
Size',12,'FontWeight','bold');
%     plot(valors(10+cont,1),valors(10+cont,2),'o','Linewidth',1.5)
%     cont=cont+.01:.1;
% end
% hold off
```

## 10.4 Codi NNOE Dades EMG

En el codi següent es troben totes línies necessàries per generar un model no lineal nnoe. Com en els casos anteriors dels models lineals, el procediment és molt similar. En primera instància es determina en quina localització es troben les dades per a poder carregar-les posteriorment. Una vegada determinada la localització es procedeix a llegir les dades dels senyals i a graficar-los mitjançant un 'plot'.

Tan bon punt s'han visualitzat les dades, es preparen els vectors de dades d'ajust i de validació del senyal EMG, als quals posteriorment se'ls aplicarà el millor model o escollit però amb l'arquitectura de xarxa neuronal, concretament el 230.

Finalment, s'executen les comandes característiques de les xarxes neuronals.

Netejar la línia de comandes i les dades

```
%%
clc;
clear all;
```

Definir on es troben les dades

```
%% Data folder name
DataFolderName='Dades EEG_VH';
%File name
FileName='L01311314';

%Define data file path
DataFilePath=[pwd filesep DataFolderName filesep FileName];

%Acces data folder
cd(DataFilePath);

%Acces to .spa data
fid=fopen([FileName '.spa'],'rt');
c=textscan(fid, repmat('%s',1,54), 'Delimiter','|', 'Headerlines',2);
Hora_Data=c{1};
fclose(fid);
```

Llegir i graficar els senyals

```
%% Read BIS signal
BIS=[cellfun(@(x)str2double(x),c{12}) ...
cellfun(@(x)str2double(x),c{26}) ...
cellfun(@(x)str2double(x),c{40})];
```



```

BIS(:,2:3)=[];

[pos]=find(BIS==-3276.8);
BIS(pos)=NaN;
[pos1]=find(BIS==0);
BIS(pos1)=NaN;
%% Filtre BIS
%Gaussian filter
Window= 30;
BISfiltrat = smoothdata(BIS,"gaussian",Window);

%% Read EEG signal
%Acces to .spa data
fid=fopen([FileName '.r2a'],'rb');
%EEG signal
EEG=fread(fid,[4 inf],'int16');
fclose(fid);
%convert into microvolts by 0.0511 uV/step scale factor
EEG_uV=EEG*(1675.42688/32767);
EEGbo=mean(EEG_uV,2);
%% Filtre EEG
W=200;
EEGfiltrat=smoothdata(EEGbo,"gaussian",W);

%% Read EMG signal
EMG=cellfun(@(x)str2double(x),c{44});
[pos2]=find(EMG==-327.7);
EMG(pos2)=NaN;
[pos3]=find(EMG==0);
EMG(pos3)=NaN;
%% Filtre EMG
% %Gaussian filter
Window=30;
EMGfiltrat=smoothdata(EMG,"gaussian",Window);

stdEMG=std(EMGfiltrat);
[trobpos]=find(EMGfiltrat(1)<-10*stdEMG);
EMGfiltrat(trobpos)=NaN;

```

Divisió del senyal en dades d'ajust i de validació

```

%% PERIODE DE MOSTREIG
N=length(EMG);
Ts=length(Hora_Data)/length(EMG); %diff entre 1r i ult Hora_Data
fs=1/Ts;
temps=0:Ts:(N-1)*Ts;

%% Division of the signal in training and testing sets
ent_entrenament = EMGfiltrat(1:7768,:);
ent_validacio = EMGfiltrat(7769:15536,:);
sort_entrenament = BISfiltrat(1:7768,1);
sort_validacio = BISfiltrat(7769:15536,1);

%% TEMPS
Nval=length(ent_validacio);
tempsval=0:Ts:(Nval-1)*Ts;
T=transpose(tempsval);
d=iddata(sort_entrenament,ent_entrenament,Ts);

```

Model no lineal NNOE

```
%% Xarxes Neuronals
```

```

NetDef = ['HHH'; 'L--']; %3 neurones, 1lineal 1hiperbòlica + ocultes
nb=2;nf=3;nk=0;
NN=[nb nf nk]; %estructura na nb nk

trparms=settrain; %Carregar els parametres per defecte d'entrenament dona
l'estructura bàsica
%trparms=settrain(trparms,'maxiter',500,'skip',2); %Canvia els param, d'entrena-
ment i per no modificar els paràmetres base s'aplica la línia 106. El num ite-
raccions max que farà (10000) en blocs de 10 en 10
[P1,P2]=nnoe(NetDef,NN,[],[],trparms,sort_entrenament',ent_entrenament'); %esti-
mació del model
% % [P3,P4]=nnoe(NetDef,NN,[],[],trparms,sort_entrenament',ent_entrenament2');
%[P1,P2]=nnoe(NetDef,NN,rand(3,4),rand(1,4),trparms,sort_entrenament',ent_en-
trenament');
[P1,P2,NSSEvec]=nnoe(NetDef,NN,[P1],[P2],trparms,sort_entrenament',ent_en-
trenament');
% % [P3,P4]=nnoe(NetDef,NN,[P3],[P4],trparms,sort_entrenament',ent_en-
trenament');
%És una normalització. Assignar pesos serveix per que la magnitud petita no
"desapareixi". Ja que parlem de uV y BIS de 0 a 100.
%Vigilar si s'ha de transposar o no les dades.
[yhat,NSSE]=nnvalid('nnoe',NetDef,NN,[P1],P2,sort_validacio',ent_validacio');
%validació del model a un horitzó d'1 mostra

Ypred1=kpredict('nnoe',NetDef,NN,1,[P1],[P2],sort_validacio',ent_validacio');
Ypred10=kpredict('nnoe',NetDef,NN,10,[P1],[P2],sort_validacio',ent_validacio');
Ypred25=kpredict('nnoe',NetDef,NN,25,[P1],[P2],sort_validacio',ent_validacio');
Ypred50=kpredict('nnoe',NetDef,NN,50,[P1],[P2],sort_validacio',ent_validacio');
Ypred75=kpredict('nnoe',NetDef,NN,75,[P1],[P2],sort_validacio',ent_validacio');
Ypred100=kpredict('nnoe',NetDef,NN,100,[P1],[P2],sort_validacio',ent_valida-
cio');
Ypred125=kpredict('nnoe',NetDef,NN,125,[P1],[P2],sort_validacio',ent_valida-
cio');
Ypred150=kpredict('nnoe',NetDef,NN,150,[P1],[P2],sort_validacio',ent_valida-
cio');

```

## 10.5 Codi NNARX Dades EMG

Abans de tot, cal mencionar que aquest codi ha estat generat per Carlota Lacasa Vela, la meua companya de TFG de la UIC. En el codi següent es troben totes línies necessàries per generar un model no lineal nnarx. Com en el cas anterior del model no lineal nnoe, el procediment és exactament igual. L'únic que varia és 'nnarx' en comptes de 'nnoe' i l'ordre del model que és 120.

Netejar la línia de comandes i les dades

```

clc;
clear all;
close all

```

Definir on es troben les dades

```

%Data folder name
DataFolderName='Data_BIS_antiguo';
%File name
FileName='L07221141';

```

```
%Define data file path
DataFilePath=[pwd filesep DataFolderName filesep FileName];
%Acces data folder
cd(DataFilePath);
```

Llegir senyal BIS

```
% Read the .spa file
%Acces to .spa data
%.spa filecontains a large plaintext tabulation of processed variables.
fid=fopen([FileName '.spa'],'rt');
c=textscan(fid, repmat('%s',1,97), 'Delimiter','|', 'Headerlines',2);
t=c{1};
fclose(fid);
% Define BIS
BIS = [cellfun(@(x)str2double(x),c{12}) ...
cellfun(@(x)str2double(x),c{32}) ...
cellfun(@(x)str2double(x),c{52})];
%% Remove the 2nd and 3th columns because the second doesn't have anything
% and the 3rd one is the same as the first
BIS(:,2:3)=[];
%Impose negative values to be NaN
BIS(BIS<0)=NaN;
%Fill NaN with previous value
BIS_fill=fillmissing(BIS,'previous');
%Gaussian filter
Window= 10;
BIS_smooth = smoothdata(BIS_fill,"gaussian",Window);
% Define EMG
EMG = cellfun(@(x)str2double(x),c{56});
```

Llegir senyal EMG

```
%Impose negative values to be NaN
EMG(EMG<0)=NaN;
%Fill NaN with previous value
EMG_fill=fillmissing(EMG,'previous');
% %Gaussian filter
Window=10;
EMG_smooth = smoothdata(EMG_fill,"gaussian",Window);
```

Divisió del senyal en dades d'ajust i de validació

```
% Division of the signal in training and testing sets
u_training = EMG_smooth(1:4606,:);
u_testing = EMG_smooth(4607:9212,:);
y_training = BIS_smooth(1:4606,:);
y_testing = BIS_smooth(4607:9212,:);
```

Model no lineal NNARX

```
%% Define the model structure
NetDef=['HHH';'L--'];
%[OrderIndexMat]=lipschit(u_training,y_training,nb,na);
NN=[1 2 0];
%% Train the network
```

```

trparms=settrain; %set parameters for training algorithm. Carregar paràmetres de
trparms=settrain(trparms, 'maxiter',300, 'skip', 10); %Anar variant progressivament
[W1,W2,NSSEvec]=nnarx(NetDef,NN,[],[],trparms,y_training', EEG_training');
%% Normalització
% Uscale=[mean(u_testing),std(u_testing)];
% Yscale=[mean(y_testing),std(y_testing)];
% [W1,W2]=wrescale('nnarx',W1,W2,Uscale',Yscale',NN); %Rescale the weights
%% Validate the generated NNarx-model
[Yhat,NSSE] = nnvalid('nnarx',NetDef,NN,W1,W2,y_testing',EEG_testing');
%% k-step ahead prediction of network output.
Ypred1=kpredict('nnarx',NetDef,NN,1,W1,W2,y_testing',EEG_testing');
Ypred10=kpredict('nnarx',NetDef,NN,10,W1,W2,y_testing',EEG_testing');
Ypred60=kpredict('nnarx',NetDef,NN,60,W1,W2,y_testing',EEG_testing');
Ypred120=kpredict('nnarx',NetDef,NN,120,W1,W2,y_testing',EEG_testing');

```

### 10.6 Taula d'Electrocompatibilitat

Taula en la qual es mostren les interferències que podia rebre el BIS. Resum dels principals aparells d'una habitació hospitalària i l'electrocompatibilitat entre ells.

B mitja (µT)	FFT Pic	TV	Nevera	Aire condicionat	Llit	Bomba d'infusió	Sistema de trucada	Binary	
46,86	0,28	OFF	OFF	OFF	OFF	OFF	OFF	000000	0
91,02	0,16	ON	OFF	OFF	OFF	OFF	OFF	100000	1
91,51	0,19	OFF	ON	OFF	OFF	OFF	OFF	010000	
92,46	0,29	OFF	OFF	ON	OFF	OFF	OFF	001000	
91,62	1,26	OFF	OFF	OFF	ON	OFF	OFF	000100	
91,02	0,19	OFF	OFF	OFF	OFF	ON	OFF	000010	
91,25	0,18	OFF	OFF	OFF	OFF	OFF	ON	000001	
91,26	0,18	ON	ON	OFF	OFF	OFF	OFF	110000	2
90,88	0,28	ON	OFF	ON	OFF	OFF	OFF	101000	
92,31	0,98	ON	OFF	OFF	ON	OFF	OFF	100100	
92,21	0,18	ON	OFF	OFF	OFF	ON	OFF	100010	
91,65	0,26	ON	OFF	OFF	OFF	OFF	ON	100001	
90,74	0,16	OFF	ON	ON	OFF	OFF	OFF	011000	
91,30	0,42	OFF	ON	OFF	ON	OFF	OFF	010100	
90,48	0,17	OFF	ON	OFF	OFF	ON	OFF	010010	
90,57	0,16	OFF	ON	OFF	OFF	OFF	ON	010001	
90,79	0,32	OFF	OFF	ON	ON	OFF	OFF	001100	
91,45	0,19	OFF	OFF	ON	OFF	ON	OFF	001010	
91,45	0,18	OFF	OFF	ON	OFF	OFF	ON	001001	
91,22	0,42	OFF	OFF	OFF	ON	ON	OFF	000110	

90,92	0,35	OFF	OFF	OFF	ON	OFF	ON	000101	
91,83	0,28	OFF	OFF	OFF	OFF	ON	ON	000011	
90,98	0,47	ON	ON	ON	OFF	OFF	OFF	111000	3
91,38	0,54	ON	ON	OFF	ON	OFF	OFF	110100	
90,58	0,15	ON	ON	OFF	OFF	ON	OFF	110010	
90,57	0,15	ON	ON	OFF	OFF	OFF	ON	110001	
90,71	0,71	ON	OFF	ON	ON	OFF	OFF	101100	
91,67	0,17	ON	OFF	ON	OFF	ON	OFF	101010	
91,87	0,16	ON	OFF	ON	OFF	OFF	ON	101001	
90,47	0,58	ON	OFF	OFF	ON	ON	OFF	100110	
91,20	0,61	ON	OFF	OFF	ON	OFF	ON	100101	
92,39	0,28	ON	OFF	OFF	OFF	ON	ON	100011	
90,93	0,65	OFF	ON	ON	ON	OFF	OFF	011100	
89,78	0,19	OFF	ON	ON	OFF	ON	OFF	011010	
90,57	0,27	OFF	ON	ON	OFF	OFF	ON	011001	
90,60	0,41	OFF	ON	OFF	ON	ON	OFF	010110	
90,56	0,39	OFF	ON	OFF	ON	OFF	ON	010101	
90,71	0,28	OFF	ON	OFF	OFF	ON	ON	010011	
92,16	1,21	OFF	OFF	ON	ON	ON	OFF	001110	
92,65	0,85	OFF	OFF	ON	ON	OFF	ON	001101	
90,77	0,17	OFF	OFF	ON	OFF	ON	ON	001011	
90,67	0,52	OFF	OFF	ON	ON	ON	ON	000111	
90,85	0,73	ON	ON	ON	ON	OFF	OFF	111100	4
90,54	0,14	ON	ON	ON	OFF	ON	OFF	111010	
90,19	0,19	ON	ON	ON	OFF	OFF	ON	111001	
90,89	0,74	ON	ON	OFF	ON	ON	OFF	110110	
91,38	0,95	ON	ON	OFF	ON	OFF	ON	110101	
92,07	0,26	ON	ON	OFF	OFF	ON	ON	110011	
90,60	0,86	ON	OFF	ON	ON	ON	OFF	101110	
92,42	0,14	ON	OFF	ON	ON	OFF	ON	101101	
91,43	0,16	ON	OFF	ON	OFF	ON	ON	101011	
90,88	0,54	ON	OFF	OFF	ON	ON	ON	100111	
91,81	1,09	OFF	ON	ON	ON	ON	OFF	011110	
90,30	0,62	OFF	ON	ON	ON	OFF	ON	011101	
92,23	0,32	OFF	ON	ON	OFF	ON	ON	011011	
90,52	0,98	OFF	ON	OFF	ON	ON	ON	010111	
90,12	0,74	OFF	OFF	ON	ON	ON	ON	001111	
90,25	0,70	ON	ON	ON	ON	ON	OFF	111110	5


90,70	0,52	ON	ON	ON	ON	OFF	ON	1111Ø1	
89,75	0,19	ON	ON	ON	OFF	ON	ON	111Ø11	
90,60	0,54	ON	ON	OFF	ON	ON	ON	11Ø111	
91,42	1,31	ON	OFF	ON	ON	ON	ON	1Ø1111	
90,53	1,09	OFF	ON	ON	ON	ON	ON	Ø11111	
91,30	1,08	ON	ON	ON	ON	ON	ON	111111	6

## 10.1 Gràfics

En aquest apartat es mostren totes les gràfiques que durant la memòria s'han mostrat en mida petita i les quals no es poden apreciar amb detall.


### 10.1.1 BIS Original

Senyal de sortida BIS sense cap filtre aplicat.




### 10.1.2 BIS vs BIS Filtrat

Senyal de sortida BIS amb un filtre gaussià aplicat.




### 10.1.3 EMG Original

Senyal d'entrada EMG sense cap filtre aplicat.



### 10.1.4 EMG vs EM G Filtrat


Senyal d'entrada EMG amb un filtre gaussià aplicat.





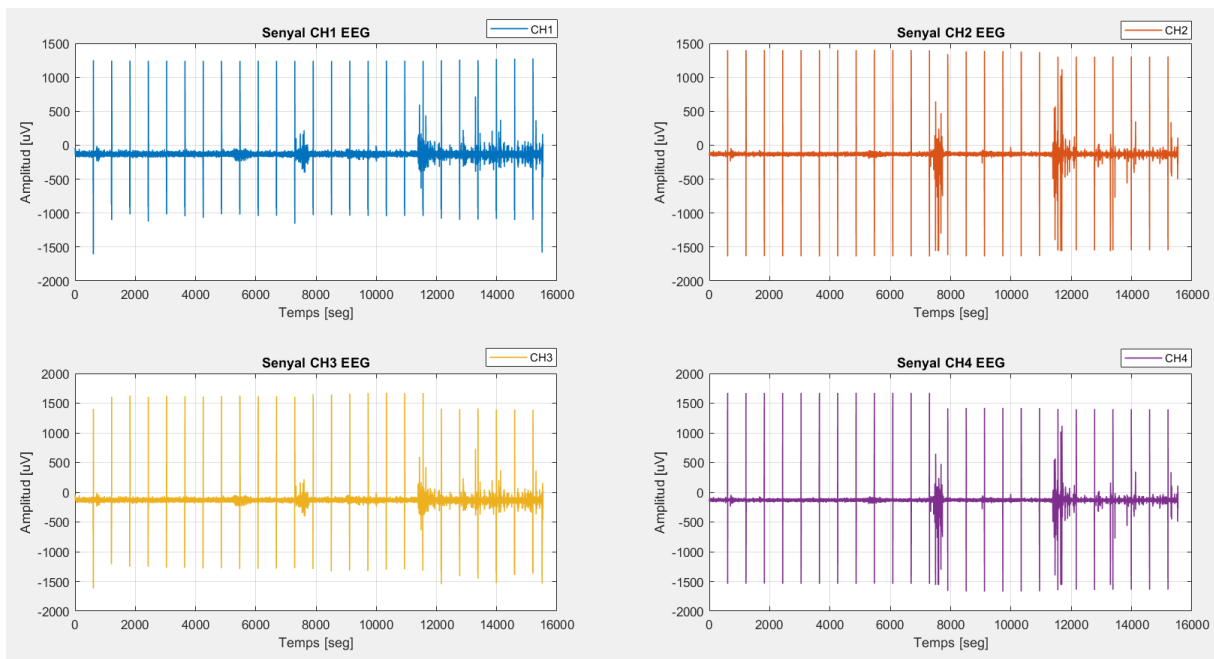
### 10.1.5 EEG Original

Senyal d'entrada EEG sense cap filtre aplicat.




### 10.1.6 4 canals d'EEG

Senyal d'entrada EEG sense cap filtre aplicat amb els 4 canals separats.




### 10.1.7 EEG Mig dels 4 canals

Senyal d'entrada EEG (mitja dels 4 canals) sense cap filtre aplicat.




### 10.1.8 EEG vs EEG Filtrat

Senyal d'entrada EEG (mitja dels 4 canals) amb un filtre gaussià aplicat.



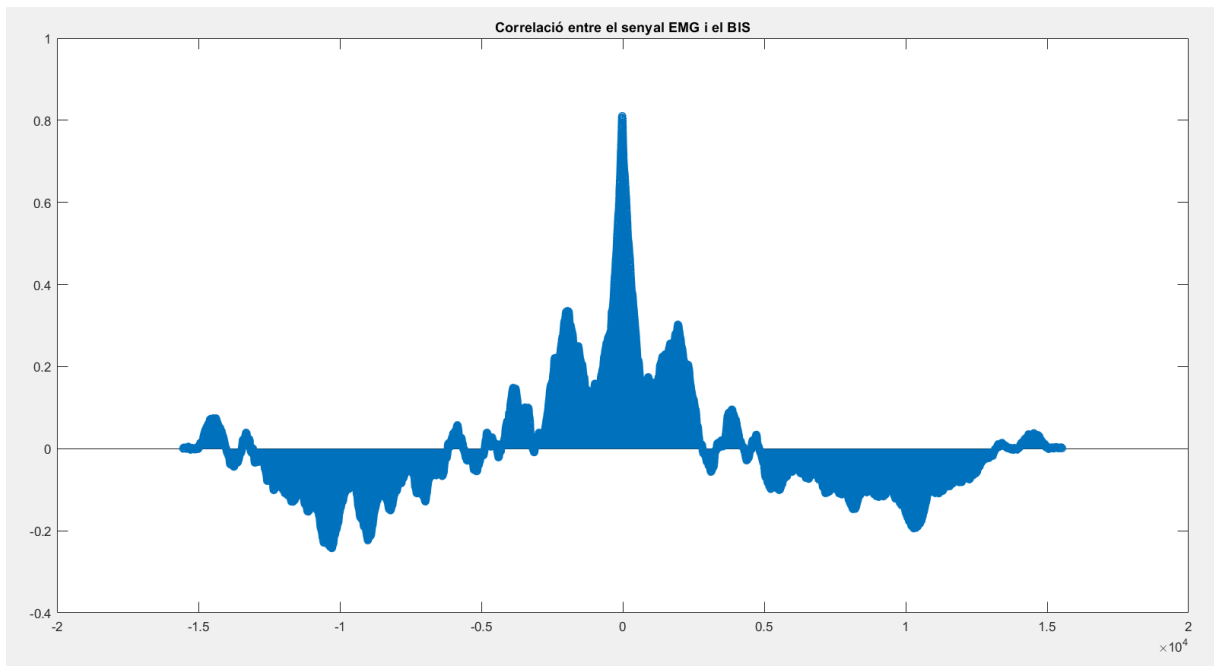
### 10.1.9 EMG + BIS + EEG

Comparació entre els dos senyals d'entrada i el de sortida.




### 10.1.10 Correlació normalitzada entre EMG i BIS:

Gràfic que mostra la correlació normalitzada entre el senyal EMG i el BIS.




### 10.1.11 Correlació normalitzada entre EEG i BIS:

Gràfic que mostra la correlació normalitzada entre el senyal EEG i el BIS.




### 10.1.12 Dades entrenament vs validació senyal EMG

Divisió de dades en vectors d'ajust i de validació del senyal EMG.




### 10.1.13 Dades entrenament vs validació senyal EEG

Divisió de dades en vectors d'ajust i de validació del senyal EEG.




### 10.1.14 Resposta impulsional del senyal EMG

Resposta impulsional del senyal EMG.




### 10.1.15 Índex de correlació senyal EEG

Resposta impulsional del senyal EMG.




### 10.1.16 Resposta a un graó senyal EMG

Resposta a un graó del senyal EMG.



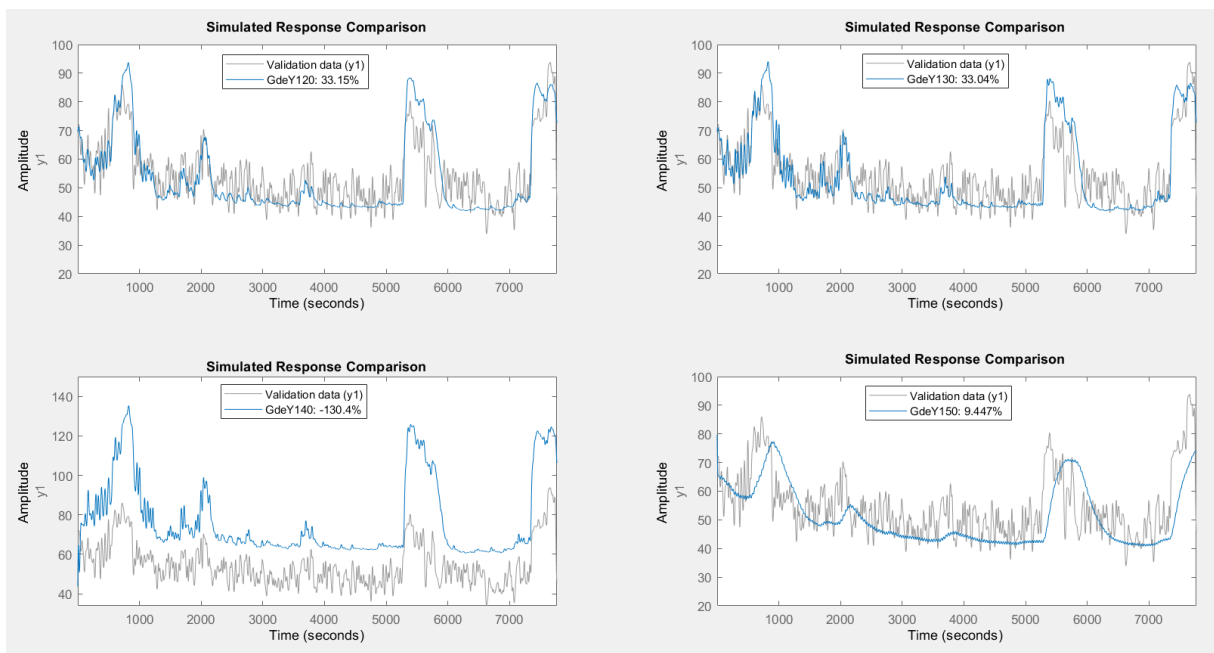
### 10.1.17 Resposta a un graó EEG

Resposta a un graó del senyal EEG.



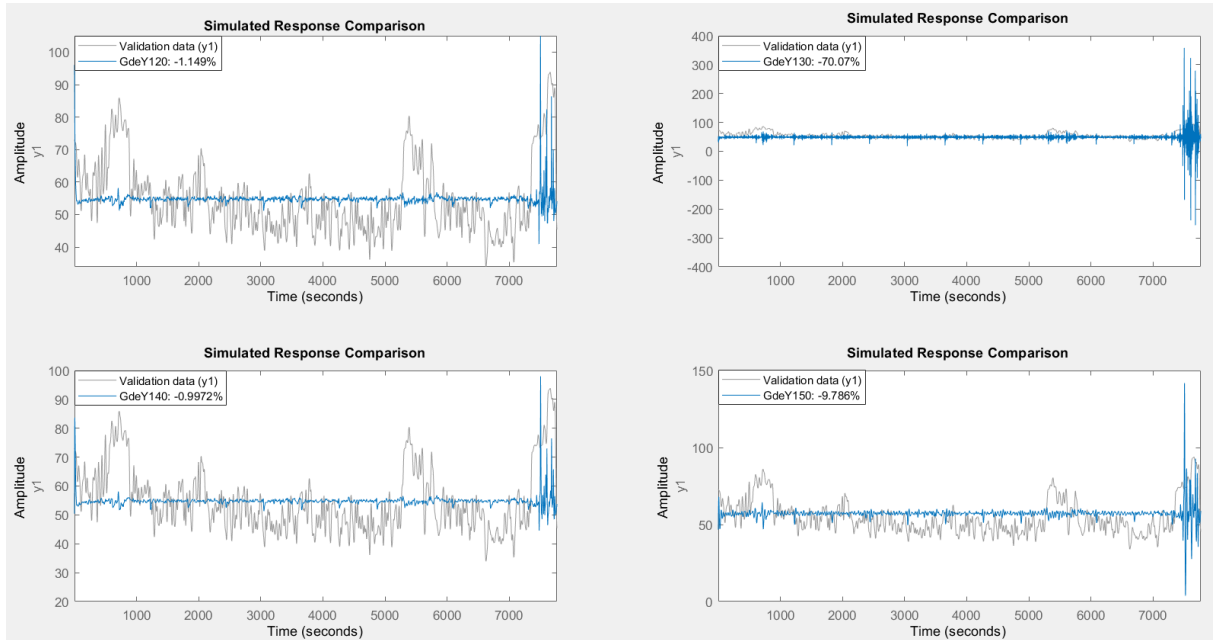
### 10.1.18 OE [120] [130] [140] [150] senyal EMG

Models lineals oe del senyal EMG amb els ordres 120, 130, 140 i 150.



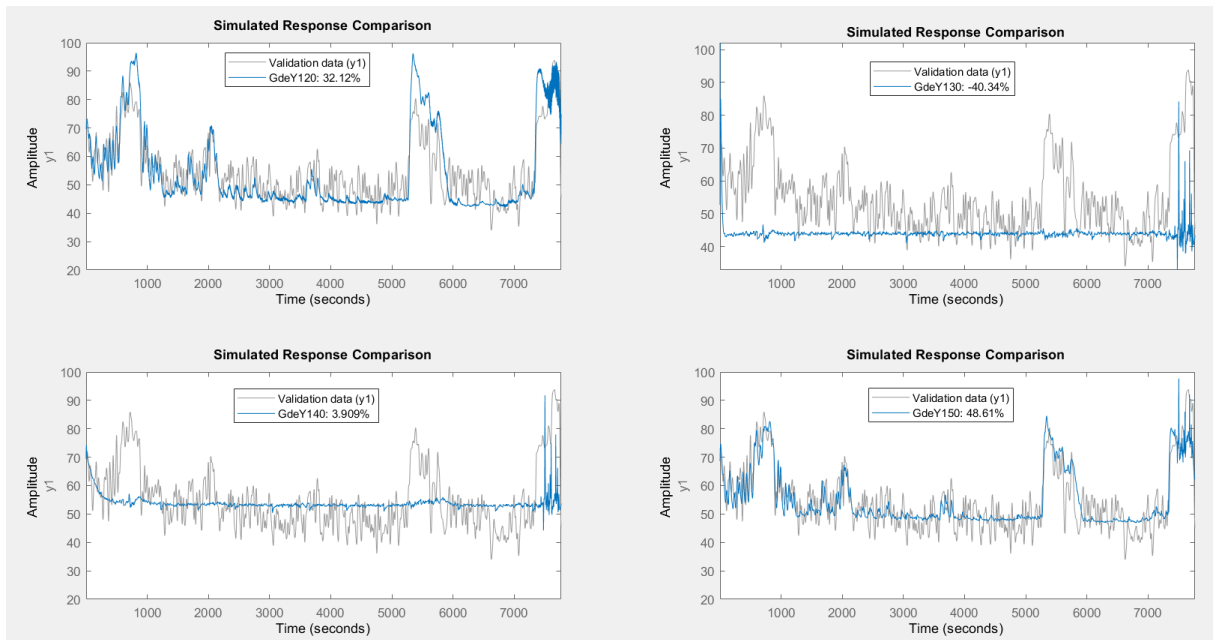
### 10.1.19 OE [120] [130] [140] [150] senyal EEG

Models lineals oe del senyal EEG amb els ordres 120, 130, 140 i 150.



### 10.1.20 OE [120] [130] [140] [150] 2 senyals d'entrada

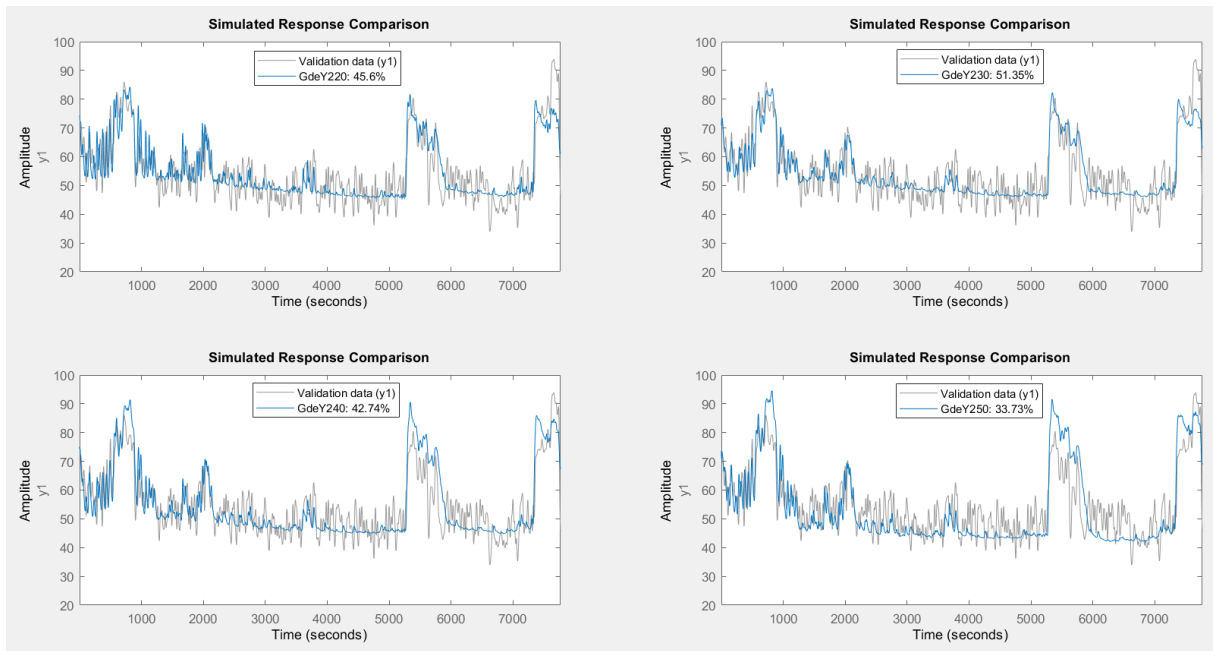
Models lineals oe dels dos senyals d'entrada (EEG i EMG) amb els ordres 120, 130, 140 i 150.





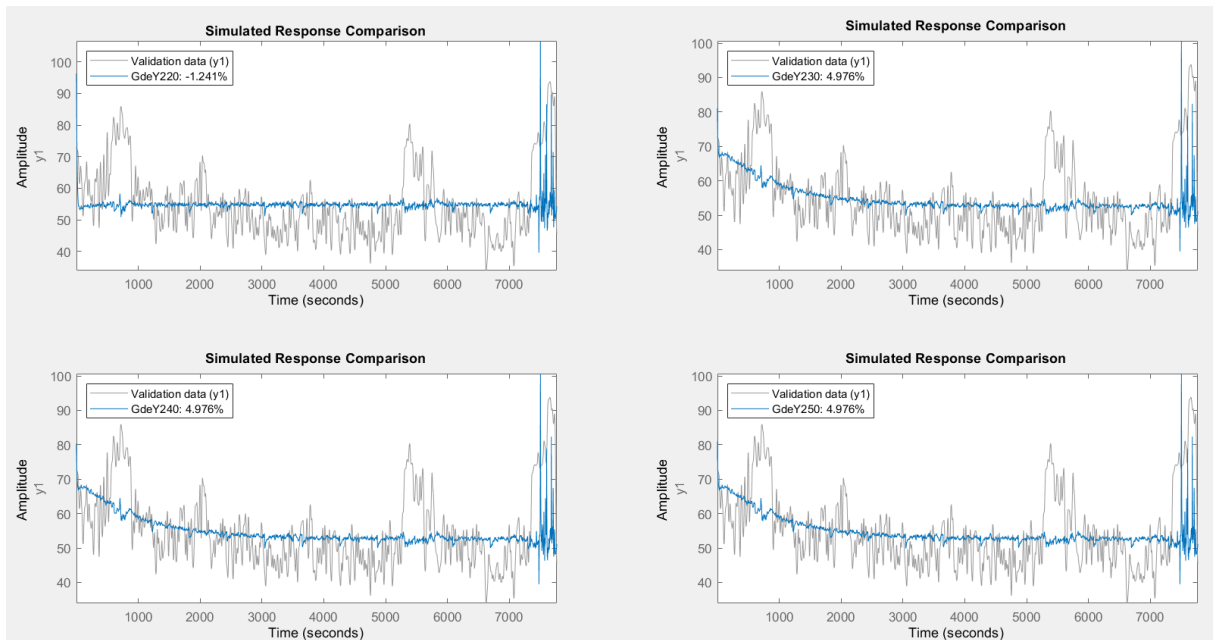
### 10.1.21 OE [220] [230] [240] [250] senyal EMG

Models lineals oe del senyal EMG amb els ordres 220, 230, 240 i 250.



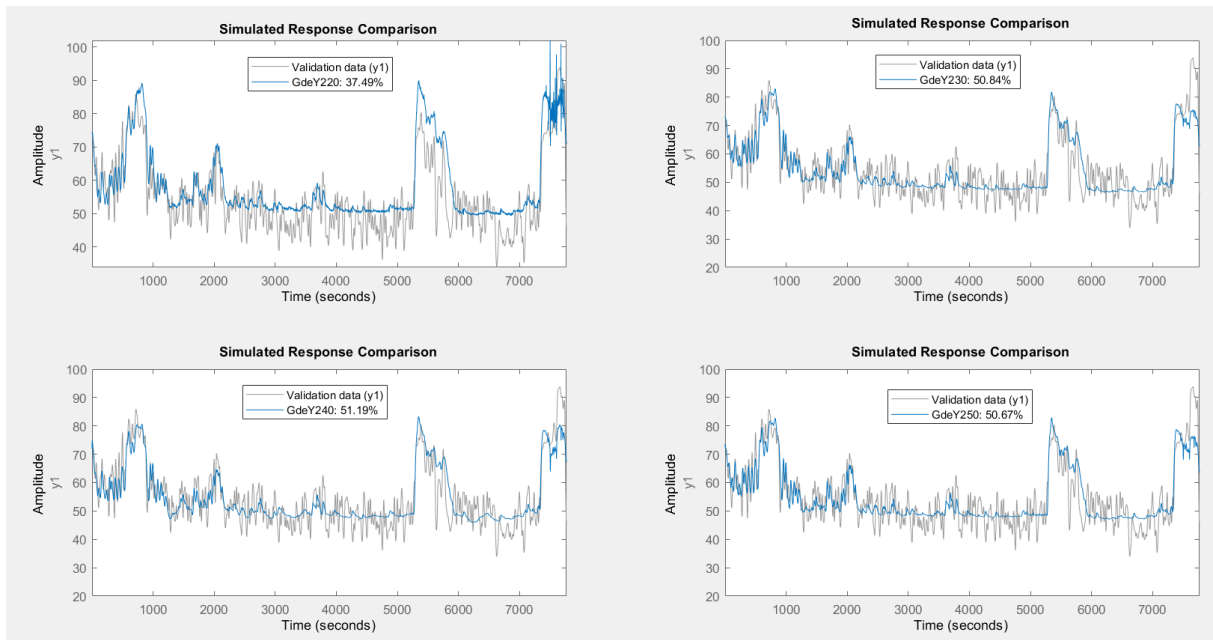
### 10.1.22 OE [220] [230] [240] [250] senyal EEG

Models lineals oe del senyal EEG amb els ordres 220, 230, 240 i 250.



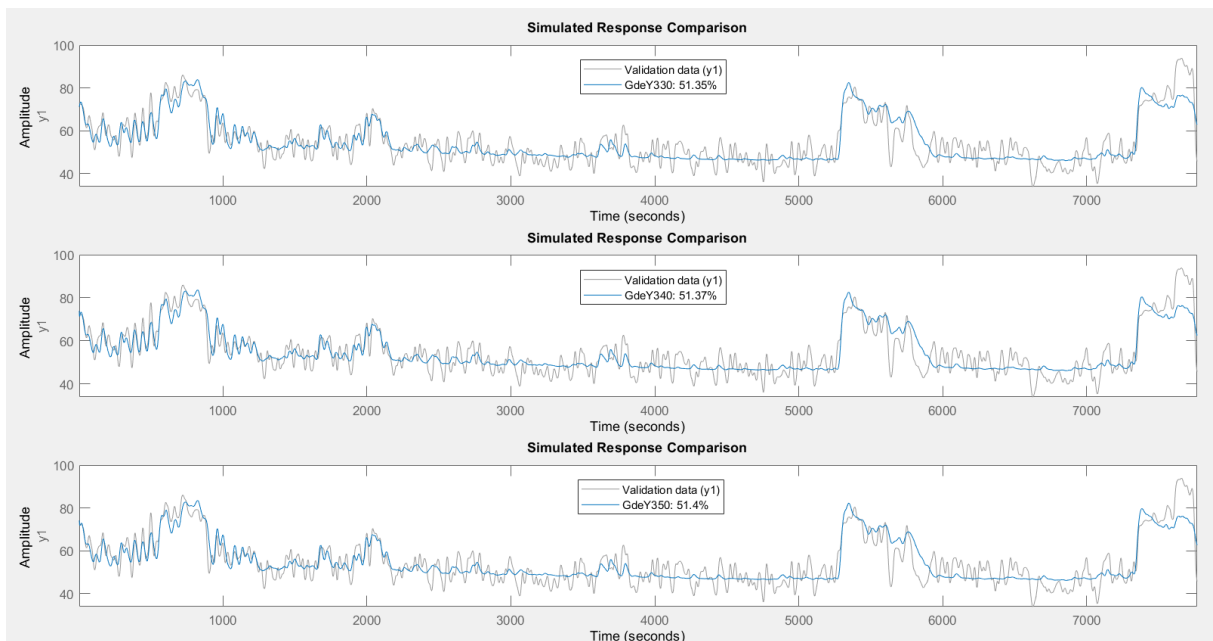
### 10.1.23 OE [220] [230] [240] [250] 2 senyals d'entrada

Models lineals oe dels dos senyals d'entrada (EEG i EMG) amb els ordres 220, 230, 240 i 250.



### 10.1.24 OE [330] [340] [350] senyal EMG

Models lineals oe del senyal EMG amb els ordres 330, 340 i 350.




### 10.1.25 OE [330] [340] [350] senyal EEG

Models lineals oe del senyal EEG amb els ordres 330, 340 i 350.



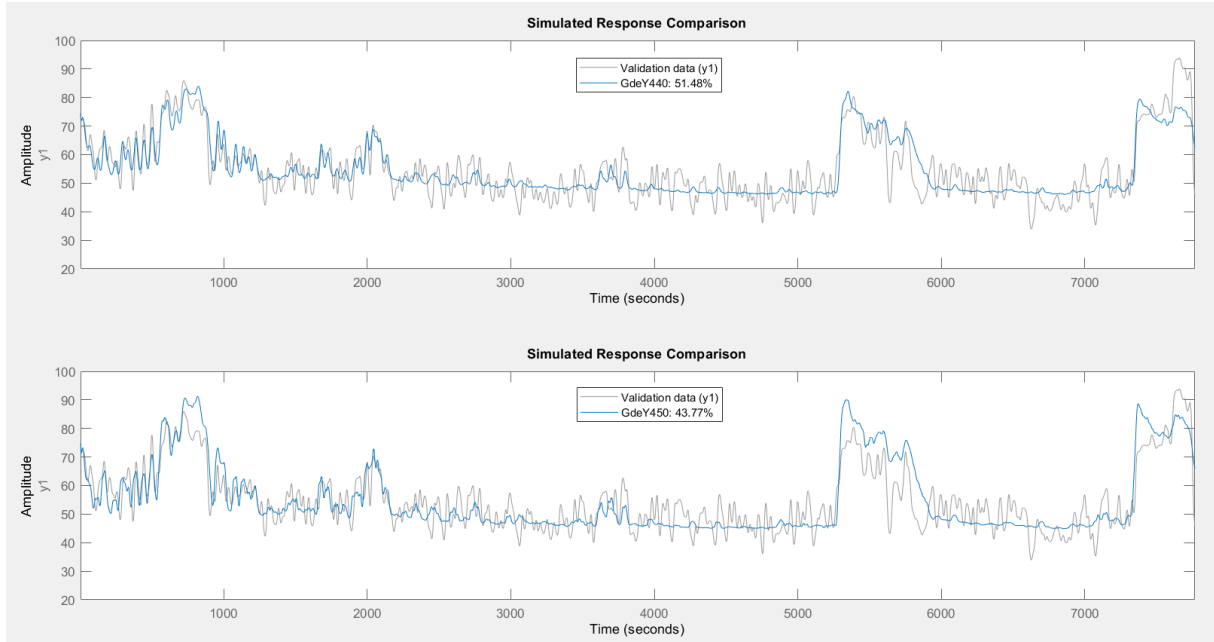
### 10.1.26 OE [330] [340] [350] 2 senyals d'entrada

Models lineals oe dels dos senyals d'entrada (EEG i EMG) amb els ordres 330, 340 i 350.




### 10.1.27 OE [440] [450] senyal EMG

Models lineals oe del senyal EMG amb els ordres 440 i 450.




### 10.1.28 OE [440] [450] senyal EEG

Models lineals oe del senyal EEG amb els ordres 440 i 450.




### 10.1.29 OE [440] [450] 2 senyals d'entrada

Models lineals oe dels dos senyals d'entrada (EEG i EMG) amb els ordres 440 i 450.




### 10.1.30 OE [550] [560] [570] senyal EMG

Models lineals oe del senyal EMG amb els ordres 550, 560 i 570.




### 10.1.31 OE [550] [560] [570] senyal EEG

Models lineals oe del senyal EEG amb els ordres 550, 560 i 570.



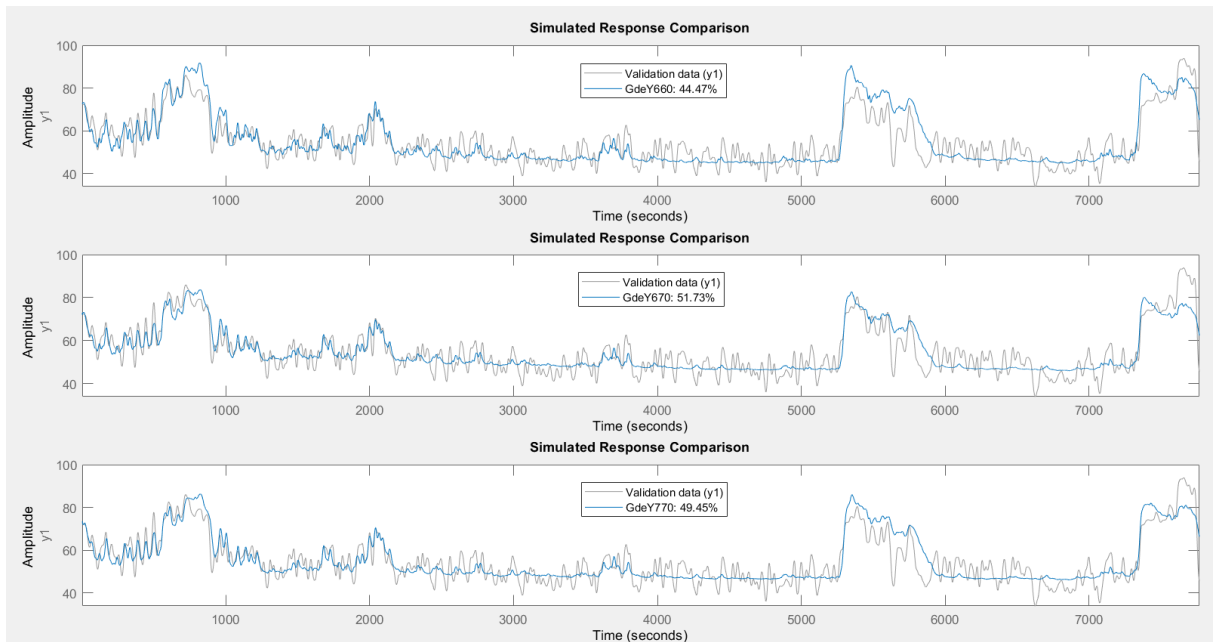
### 10.1.32 OE [550] [560] [570] 2 senyals d'entrada

Models lineals oe dels dos senyals d'entrada (EEG i EMG) amb els ordres 550, 560 i 570.




### 10.1.33 OE [660] [670] [770] senyal EMG

Models lineals oe del senyal EMG amb els ordres 660, 670 i 770.




### 10.1.34 OE [660] [670] [770] senyal EEG

Models lineals oe del senyal EEG amb els ordres 660, 670 i 770.



### 10.1.35 OE [660] [670] [770] 2 senyals d'entrada

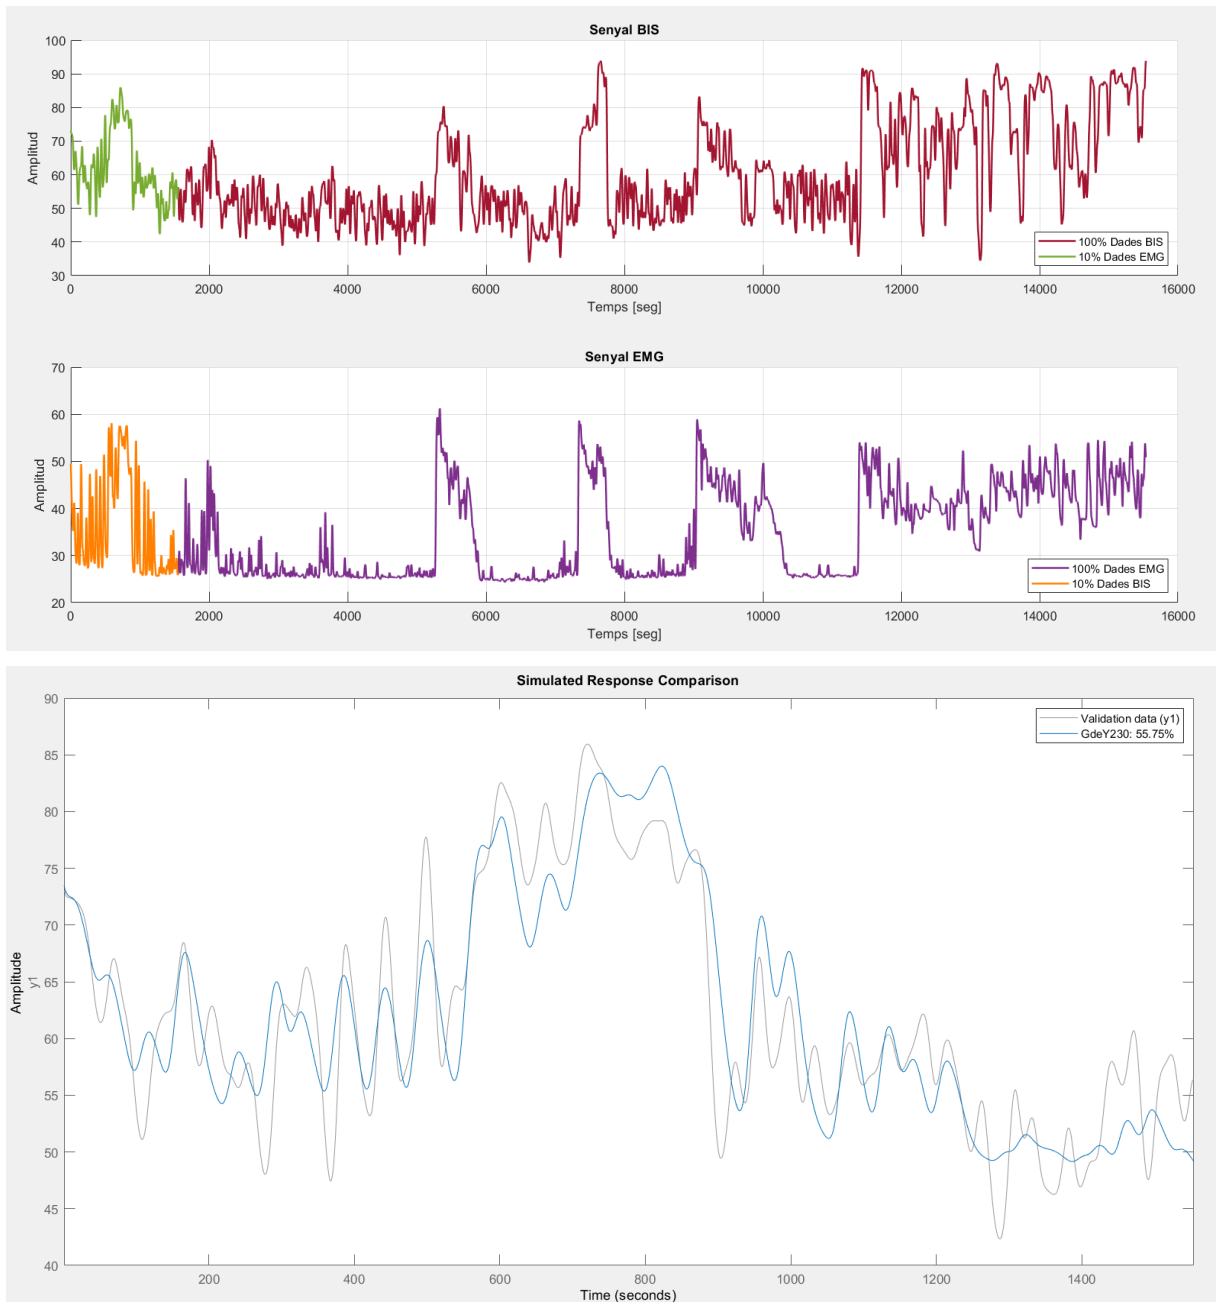
Models lineals oe dels dos senyals d'entrada (EEG i EMG) amb els ordres 660, 670 i 770.





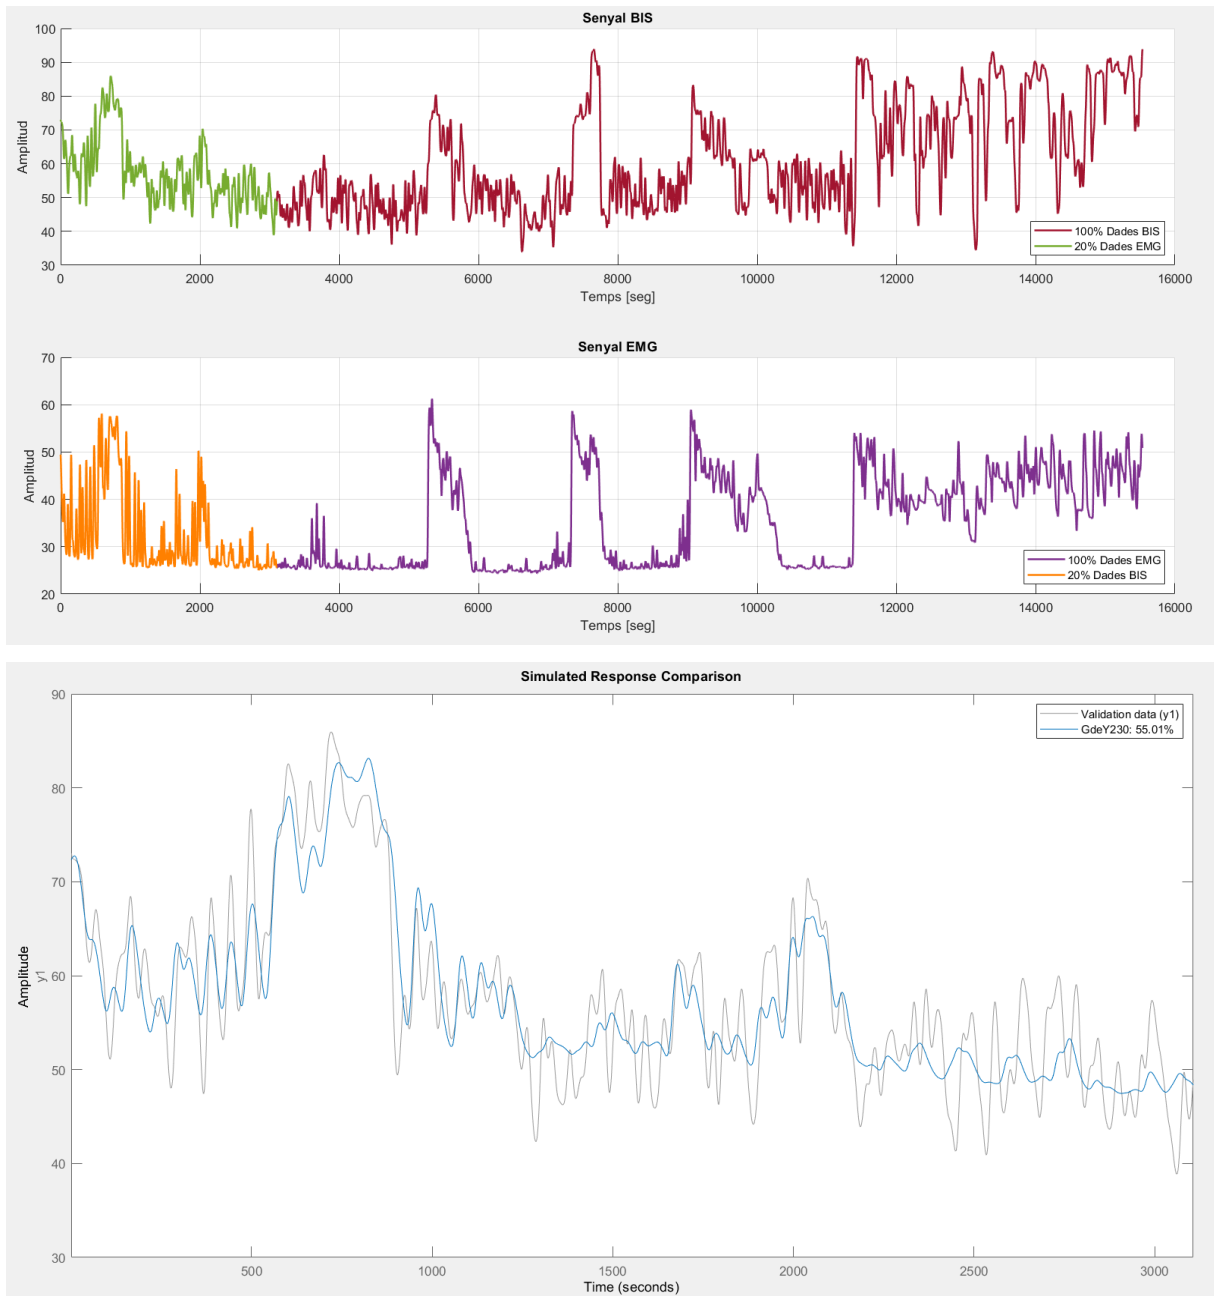
### 10.1.36 10% de dades utilitzat

Model lineal de d'ordre 230 amb un 10% de dades utilitzades.



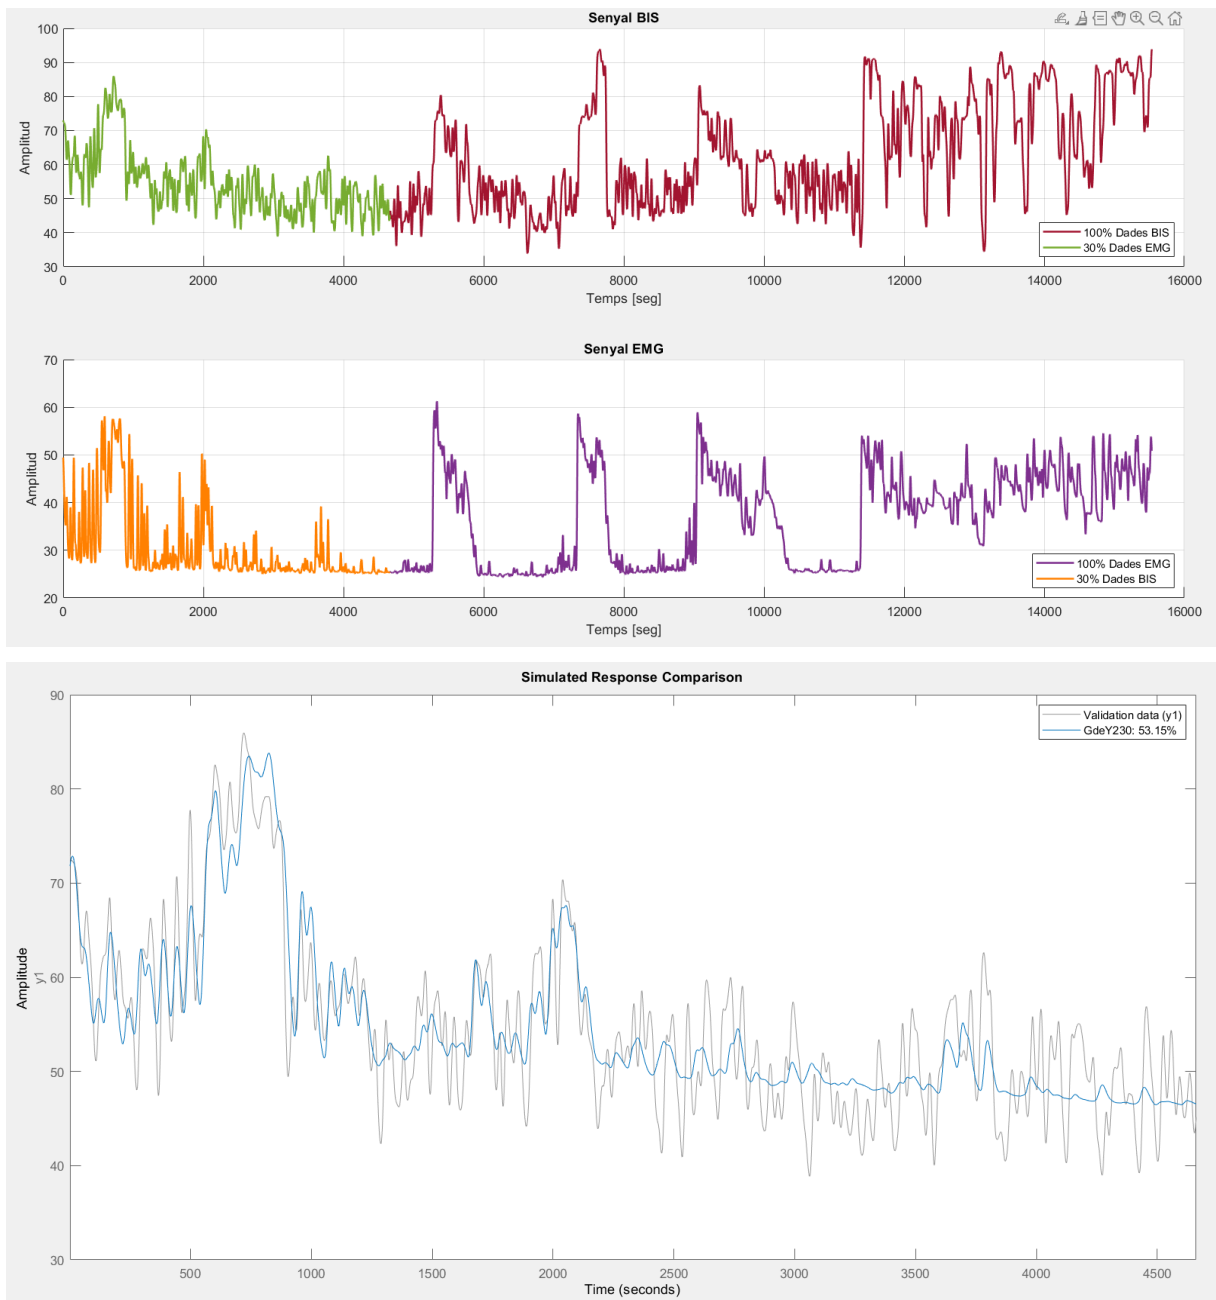
### 10.1.37 20% de dades utilitzat

Model lineal oe d'ordre 230 amb un 20% de dades utilitzades.



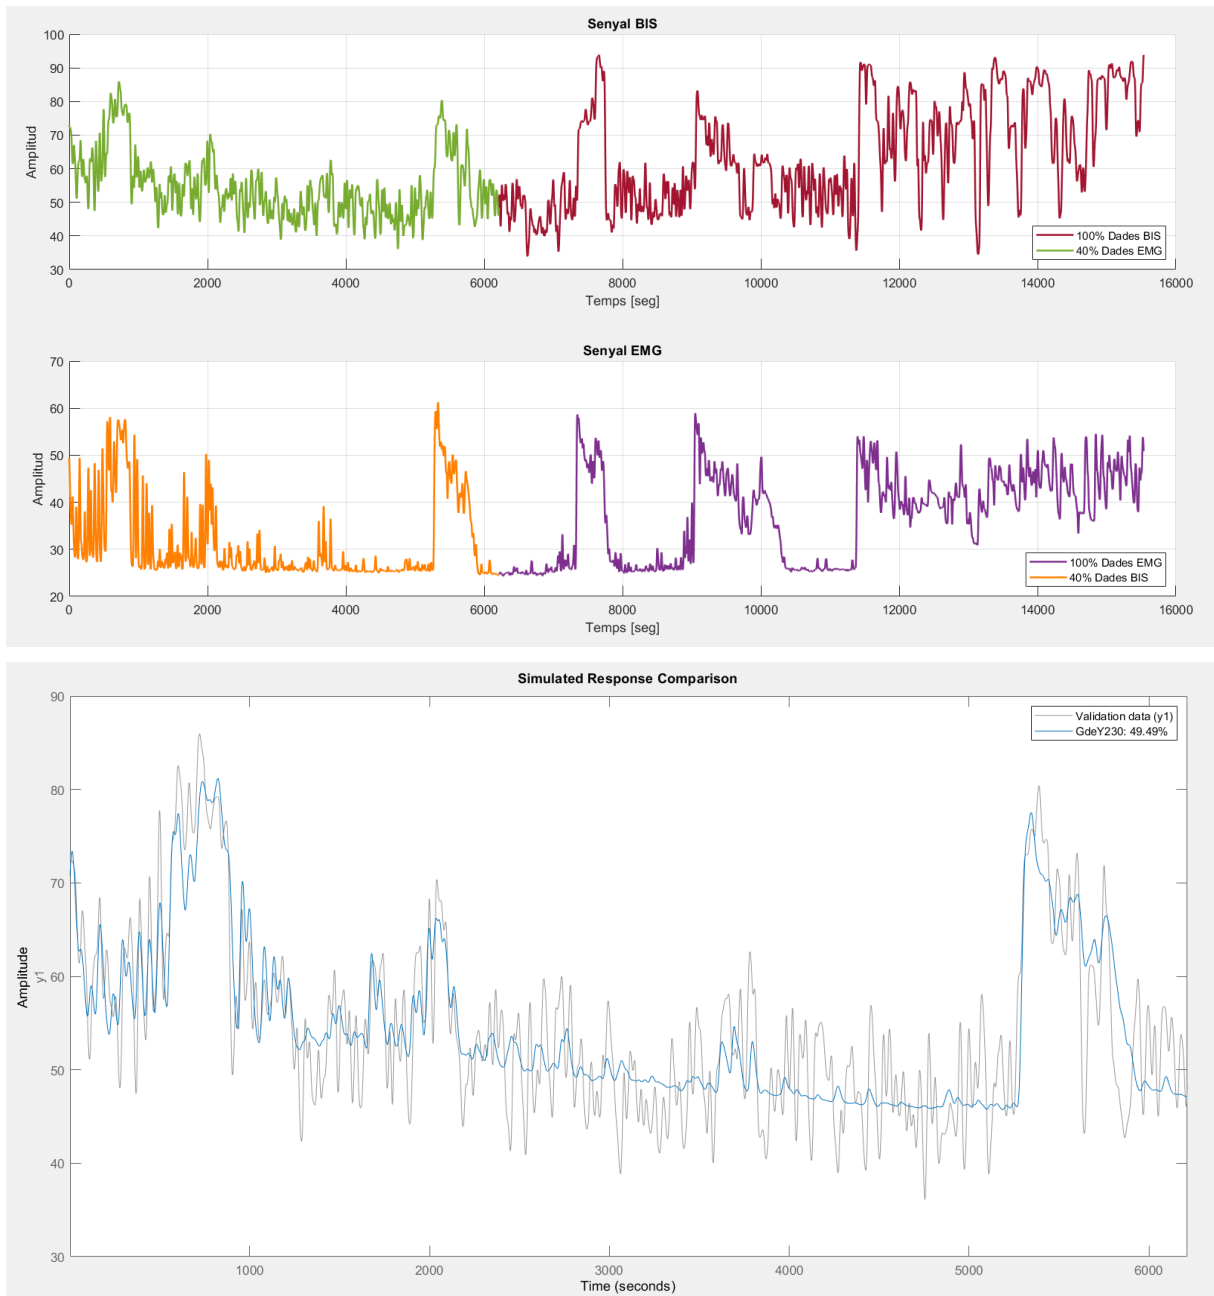
### 10.1.38 30% de dades utilitzat

Model lineal de d'ordre 230 amb un 30% de dades utilitzades.



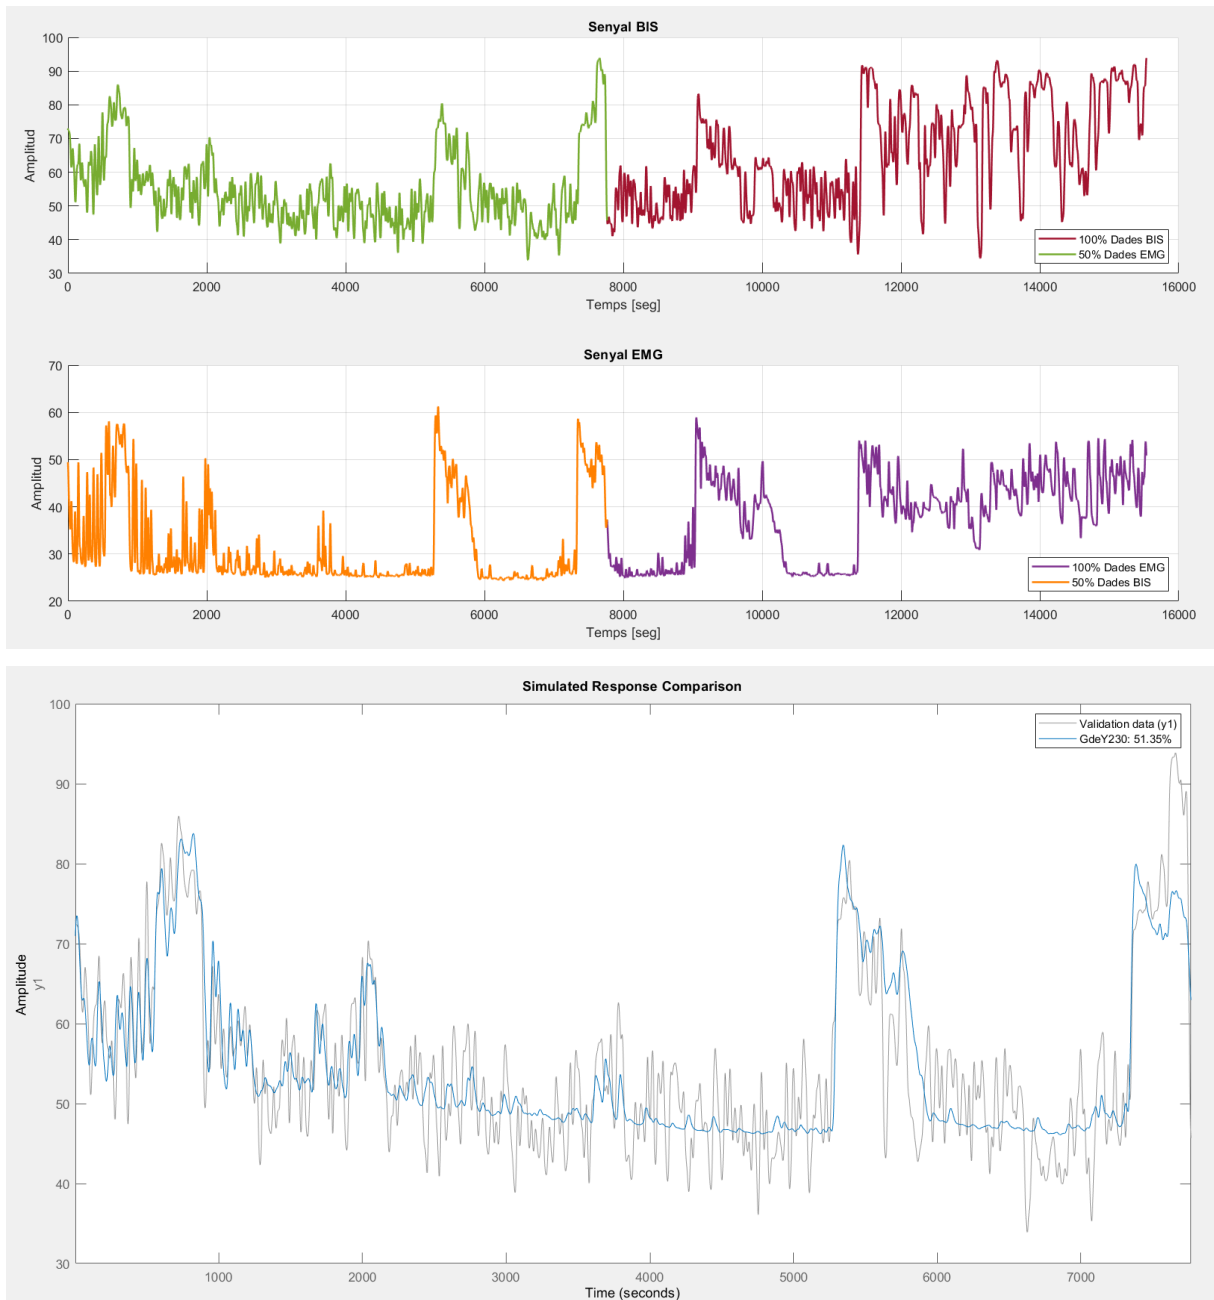
### 10.1.39 40% de dades utilitzat

Model lineal de d'ordre 230 amb un 40% de dades utilitzades.



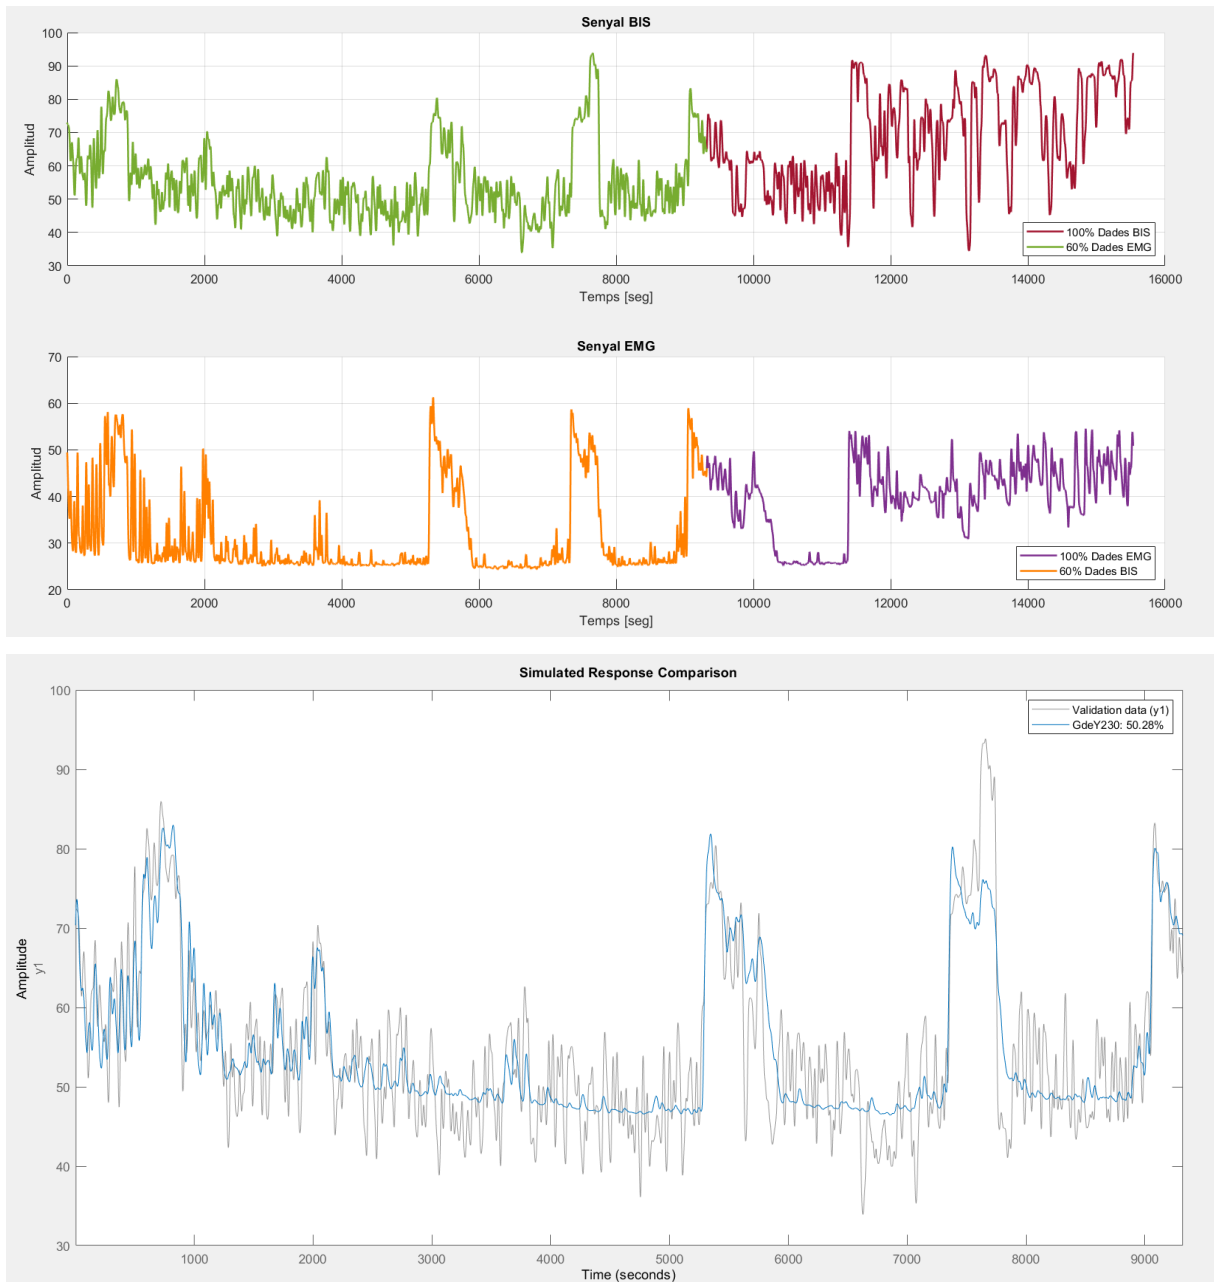
### 10.1.40 50% de dades utilitzat

Model lineal de d'ordre 230 amb un 50% de dades utilitzades.



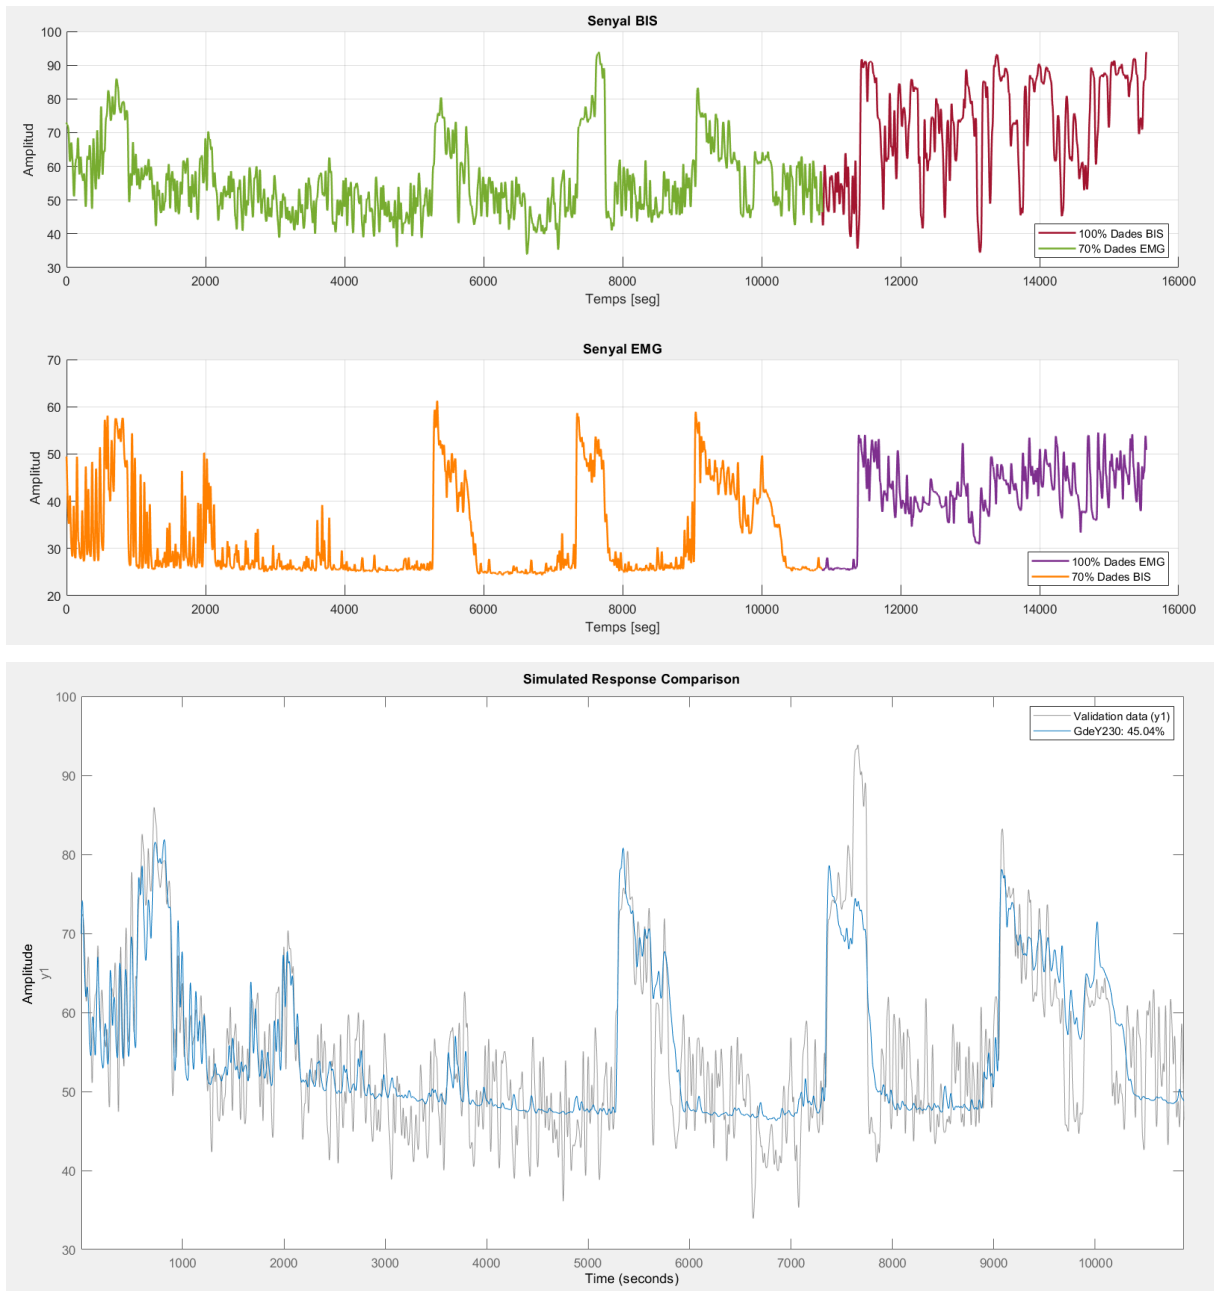
### 10.1.41 60% de dades utilitzat

Model lineal de d'ordre 230 amb un 60% de dades utilitzades.



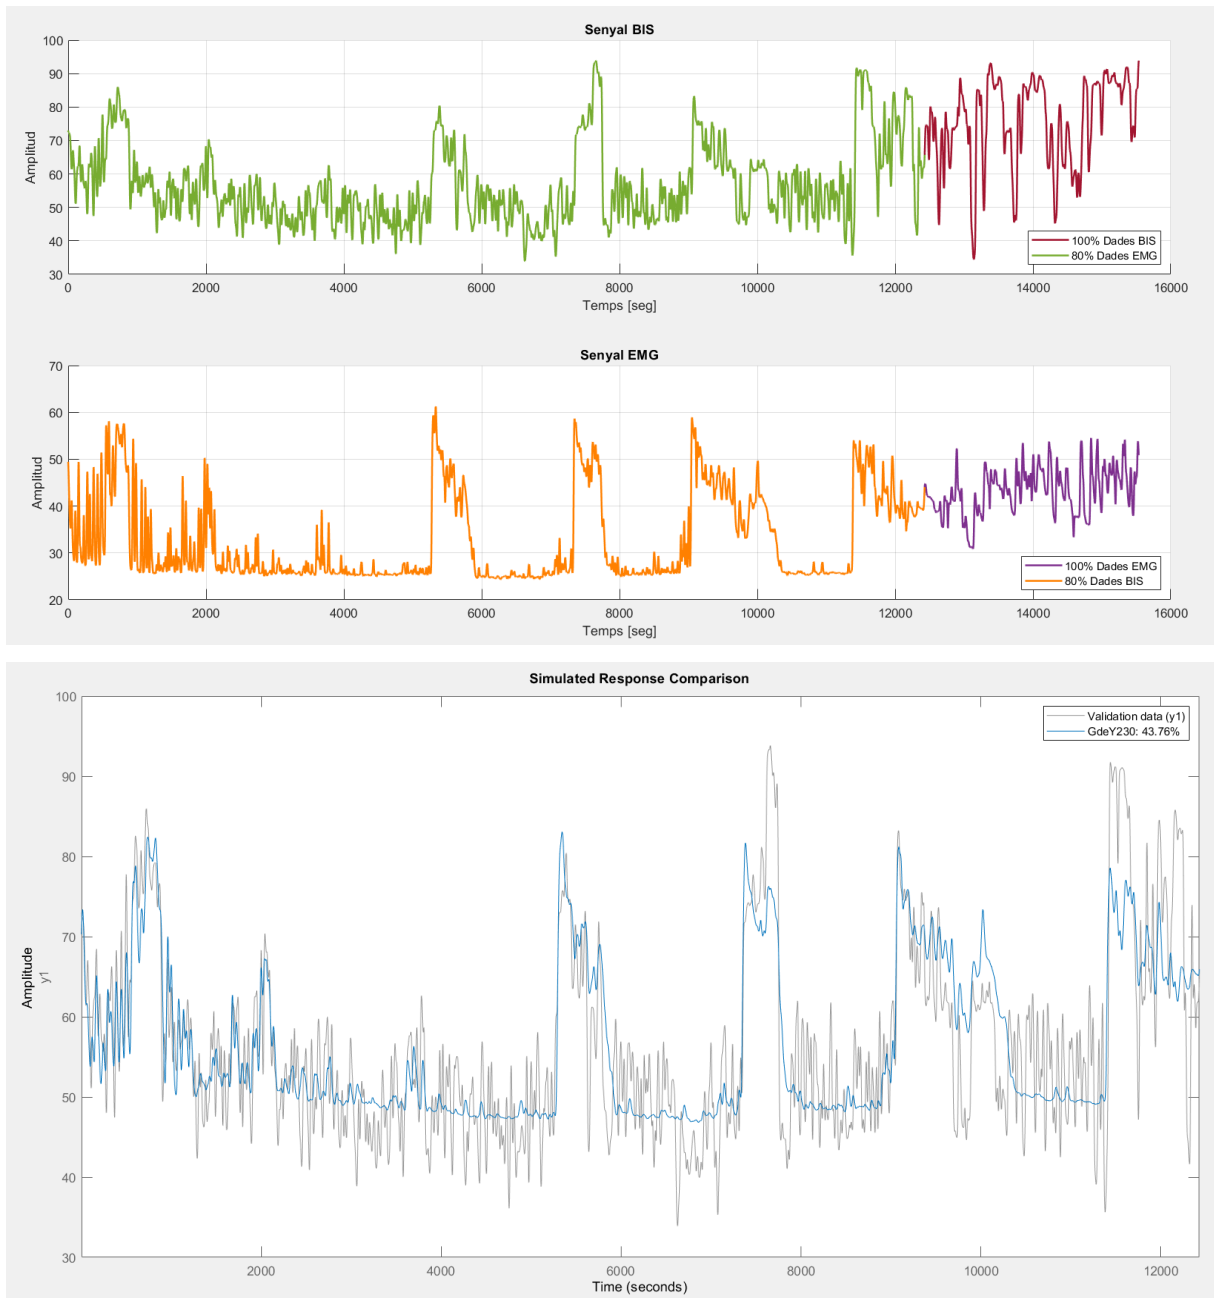
### 10.1.42 70% de dades utilitzat

Model lineal oe d'ordre 230 amb un 70% de dades utilitzades.



### 10.1.43 80% de dades utilitzat

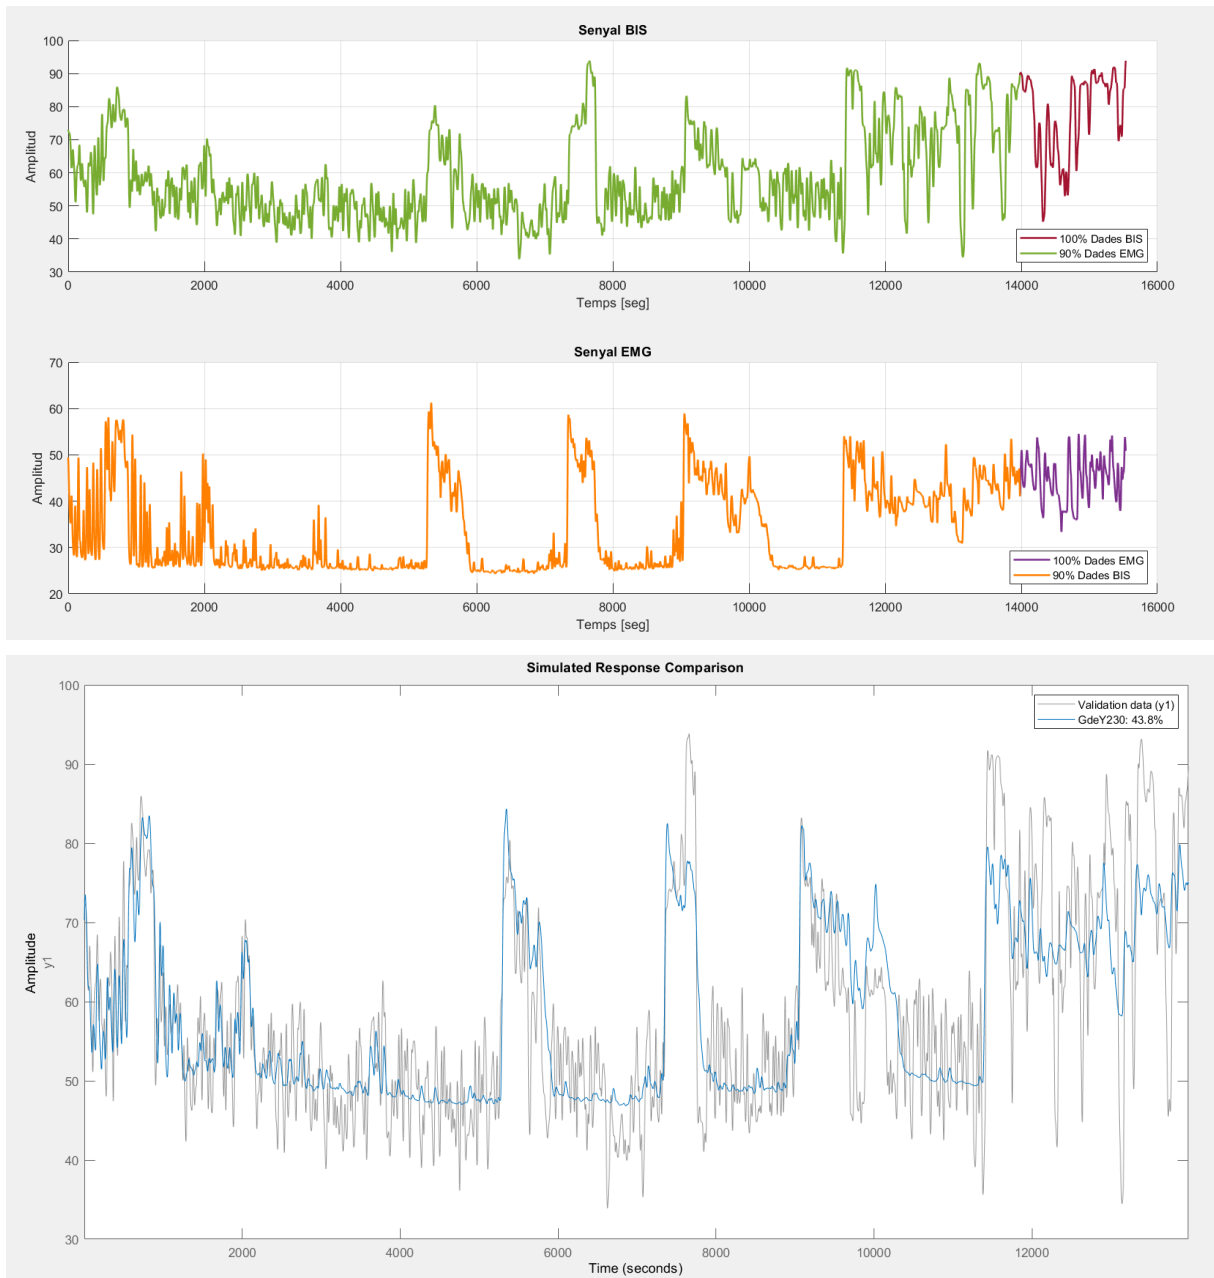
Model lineal de d'ordre 230 amb un 80% de dades utilitzades.





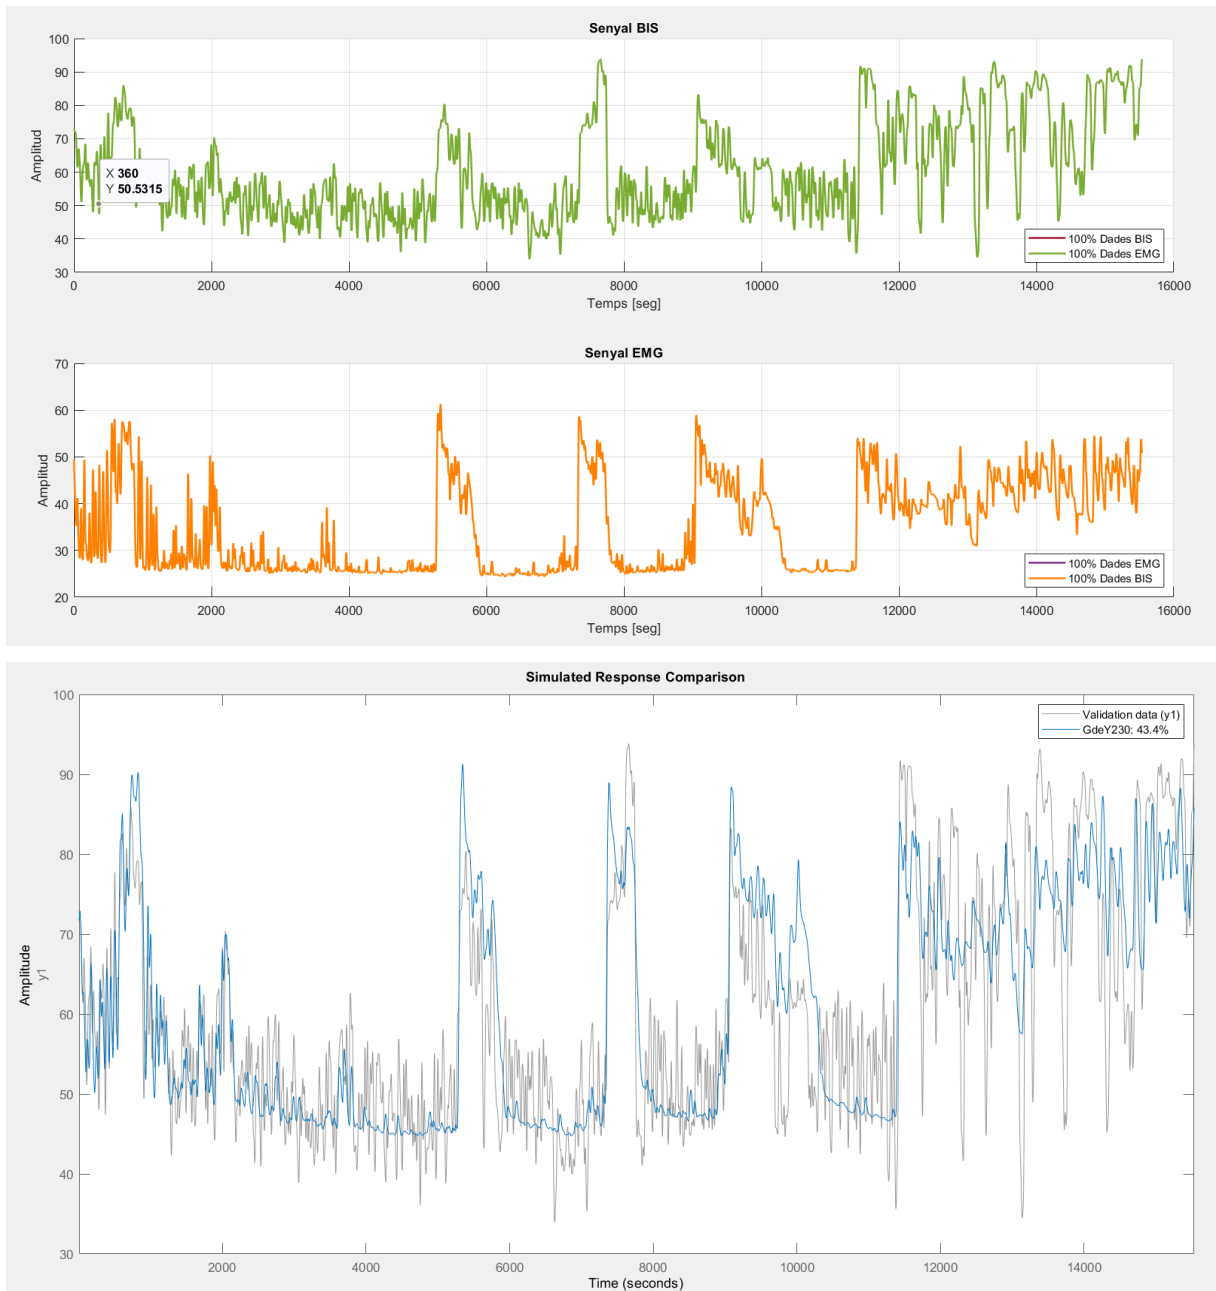
### 10.1.44 90% de dades utilitzat

Model lineal de d'ordre 230 amb un 90% de dades utilitzades.




### 10.1.45 100% de dades utilitzat

Model lineal de d'ordre 230 amb un 100% de dades utilitzades.




### 10.1.46 Variació de l'MSE en funció del % de dades utilitzades.

Gràfic que mostra la variació de l'mse del model lineal oe d'ordre 230 en funció del percentatge de dades utilitzat.




### 10.1.47 10% inicial de dades.

Gràfic que mostra la variació de l'mse del model lineal oe d'ordre 230 en funció del primer 10% de dades emprades.




### 10.1.48 10% final de dades.

Gràfic que mostra la variació de l'mse del model lineal oe d'ordre 230 en funció de l'últim 10% de dades emprades.




### 10.1.49 Model oe de l'1% de dades utilitzades.

Simulació de la resposta del model lineal oe d'ordre 230 amb un 1% de dades utilitzades.



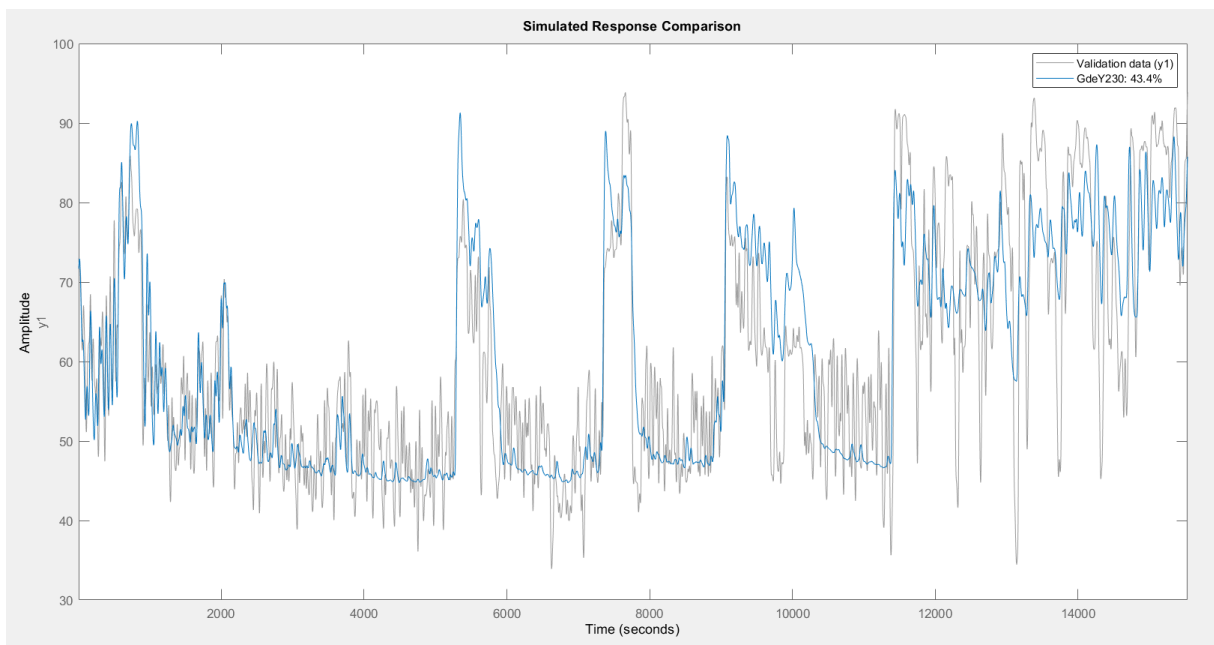
### 10.1.50 Model oe del 10% de dades utilitzades.

Simulació de la resposta del model lineal oe d'ordre 230 amb un 10% de dades utilitzades.




### 10.1.51 Model oe del 100% de dades utilitzades.

Simulació de la resposta del model lineal oe d'ordre 230 amb un 100% de dades utilitzades.




### 10.1.52 Error de l'1% de dades utilitzades.

Histograma de l'error de la resposta del model lineal oe d'ordre 230 amb un 1% de dades utilitzades.




### 10.1.53 Error del 10% de dades utilitzades.

Histograma de l'error de la resposta del model lineal oe d'ordre 230 amb un 10% de dades utilitzades.




### 10.1.54 Error del 100% de dades utilitzades.

Histograma de l'error de la resposta del model lineal oe d'ordre 230 amb un 100% de dades utilitzades.




### 10.1.55 Predicció a 1 pas.

Predicció a 1 pas del model no lineal mnoe d'ordre 230.




### 10.1.56 Predicció a 10 passos.

Predicció a 10 passos del model no lineal nnoe d'ordre 230.



### 10.1.57 Predicció a 25 passos.


Predicció a 25 passos del model no lineal nnoe d'ordre 230.





### 10.1.58 Predicció a 50 passos.

Predicció a 50 passos del model no lineal nnoe d'ordre 230.



### 10.1.59 Predicció a 100 passos.

Predicció a 100 passos del model no lineal nnoe d'ordre 230.

