



**Universitat de les
Illes Balears**

Escola Politècnica Superior

Memòria del Treball de Fi de Grau

Implementació de xarxes neuronals artificials per estimar evapotranspiració de referència a les Illes Balears amb validació per parts

Josep M^a Iglesias Franco

Grau en Enginyeria Agroalimentària i del Medi

Any acadèmic 2017-18

DNI de l'alumne: 43227070L

Treball tutelat per: Pau Carles Martí

Departament de :

S'autoritza la Universitat a incloure aquest treball en el Repositori Institucional per a la seva consulta en accés obert i difusió en línia, amb finalitats exclusivament acadèmiques i d'investigació	Autor		Tutor	
	Sí	No	Sí	No
	X		X	

Paraules clau del treball: evapotranspiració de referència, xarxes neuronals artificials, necessitats de reg

Índex general

Resum.....	7
1 Introducció.....	9
1.1 Definició d'evapotranspiració.....	9
1.2 Tipus d'Evapotranspiració.....	11
1.2.1 Evapotranspiració del cultiu de referencia ET_0	11
1.2.2 Evapotranspiració del cultiu sota condicions estàndard ET_c	11
1.2.3 Evapotranspiració del cultiu sota condicions no estàndard $ET_c aj$	12
1.3 Estimació de l'evapotranspiració.....	13
1.3.1 Mesures experimentals de l'evapotranspiració.....	13
1.3.2 Models matemàtics per a l'estimació de l'evapotranspiració.....	14
1.4 Xarxes neuronals artificials.....	14
1.4.1 Nocions d'ANNs.....	14
1.4.2 Evolució de les ANNs.....	15
1.4.3 Aplicacions de xarxes neuronals a diferents camps.....	16
1.4.4 Utilització d'ANNs en el càlcul d' Et_0	16
1.5 Objectius del treball.....	17
2 Mètodes.....	19
2.1 Dades utilitzades.....	19
2.2 Càlcul de targets.....	20
2.3 Aplicació de xarxes neuronals artificials.....	21
2.3.1 Funcionament de la xarxa i el seu entrenament.....	21
2.3.2 Error avaluat a l'entrenament.....	23
2.3.3 Funció de transferència.....	23
2.3.4 Algoritme d'aprenentatge.....	23
2.3.5 Criteri d'aturada de l'aprenentatge.....	23
2.3.6 Partició de dades.....	24
2.3.7 Arquitectura òptima.....	26
2.3.8 Inputs considerats.....	26
2.3.9 Models neuronals implementats.....	27
2.4 Fórmules empíriques.....	27
2.4.1 Equació original de Hargreaves.....	27
2.4.2 Equació de Hargreaves i Samani.....	28
2.4.3 Equació de Valiantzas.....	29
2.4.4 Ajust de les fórmules empíriques.....	29

2.5	Avaluació dels models.....	29
2.6	Implementació amb Matlab.....	30
3	Resultats	34
3.1	Resultats globals	34
3.2	Resultats per estacions	35
3.3	Resultats per any de test	37
3.4	Selecció de l'arquitectura òptima	38
4	Conclusions	40
5	Bibliografia.....	41
6	Annexes	44
6.1	Resultats per estació i mitjanes globals dels models neuronals.....	44
6.2	Resultats per estació i mitjanes globals dels models empírics sense calibrar	45
6.3	Resultats per estació i mitjanes globals dels models empírics calibrats.....	46
6.4	Indicadors desglossats per any de test	47
6.4.1	RRMSE	47
6.4.2	AARE.....	49
6.4.3	MAE.....	51
6.5	Selecció d'arquitectura òptima segons el criteri de test i validació	53
6.6	Programes implementats amb Matlab	55
6.6.1	Depurades.....	55
6.6.2	Mileni	56
6.6.3	Ordena2	56
6.6.4	Combinacions3.....	56
6.6.5	Final.....	57
6.6.6	Validació4.....	57
6.6.7	Inout5.....	57
6.6.8	Conjunt.....	58
6.6.9	Prova1	58
6.6.10	Hgp2	61
6.6.11	Estàndard	63
6.6.12	Arq.....	63
6.6.13	Anydetest.....	63
6.6.14	Càlcul de PM-56	63
6.7	Instrumentes de mesura a les estacions del SIAR.....	65
6.7.1	Anemoveleta	65

6.7.2	Pluviòmetre.....	66
6.7.3	Datalogger.....	67
6.7.4	Termohigròmetre.....	68
6.7.5	Piranòmetre	69

Índex de figures

Figura 1: Factors que afecten l'evapotranspiració FAO-56 (Allen et. al. 1998)	10
Figura 2: Evapotranspiració de referència (ET_0) FAO-56 (Allen et. al. 1998)	11
Figura 3: Evapotranspiració del cultiu sota condicions estàndard (ET_c) FAO-56 (Allen et. al. 1998)	12
Figura 4: Evapotranspiració del cultiu sota condicions no estàndard ($ET_{c aj}$) FAO-56 (Allen et. al. 1998)	13
Figura 5: Esquema d'una neurona biològica (Wikimedia Commons).....	15
Figura 6: Mapa de les estacions del SIAR.....	19
Figura 10: Funcionament de la xarxa neuronal	21
Figura 11: Esquema de les diferents capes de la xarxa neuronal	22
Figura 12: Configuració de les neurones aplicades (Martí et. al. 2010)	22
Figura 13: Criteri d'aturada de l'entrenament per validació	24
Figura 14: Hold out	24
Figura 15: Leave-one-out.....	25
Figura 19: Resum dels casos contemplats a l'estudi.....	32
Figura 21: Indicador AARE dels diferents models per estacions – Adimensional (-)	36
Figura 22: Indicador MAE dels diferents models per estació – (mm/dia)	36
Figura 23: RRMSE per any de test a l'estació 1	37
Figura 24: RRMSE per any de test a l'estació 3	38
Figura 26: Selecció d'arquitectura òptima	39

Índex de taules

Taula 1: Dades de les estacions	19
Taula 2: Valors mitjans de diferents variables de les estacions.....	20
Taula 3: Desviacions estàndard de diferents variables de les estacions	20
Taula 4: Models considerats en l'estudi i els seus respectius inputs.....	27
Taula 5: Balanç de models neuronals considerats.....	27
Taula 6: Programes implementats a Matlab.....	32
Taula 7: Resultats globals dels mdoels neuronals i empírics	34
Taula 8: Nombre de neurones dels diferents models neuronals segons els dos criteris de selecció d'arquitectura òptima.....	39
Taula 9: Indicadors per estació del model Ann Rs	44
Taula 10: Indicadors per estació del model Ann Ra.....	44
Taula 11: Indicadors per estació del model Ann Hr.....	44
Taula 12: Indicadors globals per estació dels models empírics sense calibrar	45
Taula 13: Indicadors globals per estació dels models empírics calibrats.....	46

Taula 14: RRMSE per any de test del model Ann Rs amb el criteri de validació	47
Taula 15: RRMSE per any de test del model Ann Rs amb el criteri de test.....	47
Taula 16: RRMSE per any de test del model Ann Ra amb el criteri de validació	47
Taula 17: RRMSE per any de test del model Ann Ra amb el criteri de test	48
Taula 18: RRMSE per any de test del model Ann Hr amb el criteri de validació	48
Taula 19: RRMSE per any de test del model Ann Hr amb el criteri de test	48
Taula 20: AARE per any de test del model Ann Rs amb el criteri de validació	49
Taula 21: AARE per any de test del model Ann Rs amb el criteri de test	49
Taula 22: AARE per any de test del model Ann Ra amb el criteri de validació	49
Taula 23: AARE per any de test del model Ann Ra amb el criteri de test	50
Taula 24: AARE per any de test del model Ann Hr amb el criteri de validació	50
Taula 25: AARE per any de test del model Ann Hr amb el criteri de test	50
Taula 26: MAE per any de test del model Ann Rs amb el criteri de validació	51
Taula 27: MAE per any de test del model Ann Rs amb el criteri de test	51
Taula 28: MAE per any de test del model Ann Ra amb el criteri de validació	51
Taula 29: MAE per any de test del model Ann Ra amb el criteri de test	52
Taula 30: MAE per any de test del model Ann Hr amb el criteri de validació	52
Taula 31: : MAE per any de test del model Ann Hr amb el criteri de test	52
Taula 32: N° de neurones ocultes per any de test en el model Ann Rs amb el criteri de validació	53
Taula 33: N° de neurones ocultes per any de test en el model Ann Rs amb el criteri de test	53
Taula 34: N° de neurones ocultes per any de test en el model Ann Ra amb el criteri de validació	53
Taula 35: N° de neurones ocultes per any de test en el model Ann Ra amb el criteri de test	54
Taula 36: N° de neurones ocultes per any de test en el model Ann Hr amb el criteri de validació	54
Taula 37: N° de neurones ocultes per any de test en el model Ann Hr amb el criteri de test	54

Índex d'equacions

1. Equació de Penman-Monteith (mm/dia)
2. Equació de les neurones per al càlcul del valor de sortida
3. Output de la neurona
4. MSE
5. Error comés per la xarxa
6. Algoritme de Levenberg-Marquardt
7. Equació de Hargreaves (mm/dia)
8. Relació Rs/Ra
9. Equació de Hargreaves i Samani (mm/dia)
10. Càlcul de la radiació extraterrestre ($MJ m^{-2} \cdot dia^{-1}$)
11. Distància relativa inversa Terra-Sol
12. Declinació solar (radians)
13. Angle de radiació a la posta del Sol (radians)

14. X per al càlcul de w_s
15. Càlcul de R_s Valiantzas
16. Equació de Valiantzas (mm/dia)
17. Relació $Et0_{PM}$ i $Et0_k$
18. Coeficient AHC
19. MSE-*Error quadràtic mitjà*
20. RRMSE-*Error quadràtic relatiu mitjà*
21. MAE- *Error absolut mitjà*
22. R^2 -*Coeficient de determinació*
23. AARE- *Mitjana del error absolut relatiu*

Resum

L'evapotranspiració és un fenomen difícil de que depèn de diferents variables climàtiques. Per al seu càlcul o estimació actualment s'utilitzen fórmules que necessiten de gran quantitat d'inputs, com la equació de Penman-Monteith o altres com la de Hargreaves i Samani, que tot i necessitar menys inputs requereixen ser calibrades. Es per això que, com a alternativa als models tradicionals, les xarxes neuronals artificials (Artificial neural network-Ann) son cada pic mes utilitzades per modelar processos no lineals com es el cas de l'evapotranspiració. Normalment, en els estudis més comuns d'entrenament d' ANNs es separa el set de dades aplicant una única partició en 3 sets de dades: un per entrenar el model, un altre per validació creuada i un per testar el model. Per tant, l'avaluació del model estarà referida a aquesta partició. Com a alternativa a aquesta tècnica, el present estudi considera diferents particions del set de dades mitjançant la validació per parts per poder avaluar el set de dades al complet.

Així doncs s'han avaluat diferents models neuronals amb diferents combinacions d'inputs per a estimar evapotranspiració de referència. Els resultats han demostrat la capacitat dels models neuronals per a estimar el procés d'evapotranspiració, on el model ANN_{HR} ha estat el que millor error relatiu AARE presenta (0.110), seguit de ANN_{RS} (0.144) i ANN_{Ra} (0.158). A més, al comparar-se els models neuronals, ANN_{RS} , ANN_{Ra} i ANN_{HR} respecte als seus respectius models empírics, HG_{RS} , HG_{Ra} i HG_{HR} , s'ha reduït l'error relatiu AARE un 0.087, 0.064 i 0.055 respectivament.

1	Introducció.....	9
1.1	Definició d'evapotranspiració.....	9
1.2	Tipus d'Evapotranspiració.....	11
1.2.1	Evapotranspiració del cultiu de referència ET_0	11
1.2.2	Evapotranspiració del cultiu sota condicions estàndard ET_c	11
1.2.3	Evapotranspiració del cultiu sota condicions no estàndard $ET_c aj$	12
1.3	Estimació de l'evapotranspiració.....	13
1.3.1	Mesures experimentals de l'evapotranspiració.....	13
1.3.2	Models matemàtics per a l'estimació de l'evapotranspiració.....	14
1.4	Xarxes neuronals artificials	14
1.4.1	Nocions d'ANNs	14
1.4.2	Evolució de les ANNs.....	15
1.4.3	Aplicacions de xarxes neuronals a diferents camps.....	16
1.4.4	Utilització d'ANNs en el càlcul d' Et_0	16
1.5	Objectius del treball.....	17

1 Introducció

L'actual i esperada crescuda de la població ha de ser suportada amb un increment en la producció d'aliments, que ha de venir derivada del desenvolupament del sòl cultivable, de l'increment de la intensitat dels cultius, de nous sistemes de cultiu, d'incrementos en els rendiments i una millor eficiència en l'ús de l'aigua (Schults et al. 2005; Bachour et al., 2013); recurs bàsic en l'agricultura.

L'increment de la demanda d'aigua, tant d'usuaris urbans com agrícoles junt amb les sequeres i la contaminació entre d'altres, han provocat que la disponibilitat d'aigua cada pic sigui més escassa. Per tant, es requerirà d'una gestió sofisticada de l'aigua de reg per optimitzar l'eficiència del ús de l'aigua i així mantenir nivells suficients de productivitat i qualitat dels cultius (Ortega Farias et al., 2009). Per aconseguir aquest objectiu, una estimació fiable del valor d'evapotranspiració de referència pot ser de gran ajuda.

1.1 Definició d'evapotranspiració

L'evapotranspiració es basa en dos fenòmens que succeeixen a la vegada:

Evaporació: L'evaporació és el procés pel qual l'aigua líquida es converteix en vapor d'aigua. Aquest fenomen ocorre a moltes superfícies diferents com llacs, rius, extensions de terra, vegetació que té en la seva superfície aigua, etc. Per a que es dugui a terme aquest procés, les molècules d'aigua necessiten excitar-se fins al punt on canvien d'estat líquid a vapor. Aquesta excitació es produeix gràcies a l'energia que incideix a aquestes molècules que, en el nostre cas, prové, en major part, de la radiació solar i, en menor mesura, de la temperatura. Apart, a la vegada que es va evaporant l'aigua, l'aire es va carregant d'aigua, fet que provoca que el procés de evaporació sigui més lent, fins al moment en que l'aire no admet més aigua, punt de saturació. Així doncs, si no es renova l'aire carregat d'aigua, el procés d'evaporació serà més lent. L'encarregat, en aquest cas, de retirar l'aire amb les molècules d'aigua, es el vent.

És a dir, temperatura, radiació, humitat atmosfèrica y velocitat del vent, defineixen l'evaporació que sofrirà una superfície i en el cas de grans superfícies de terra intervenen altres factors en la evapotranspiració, com la cobertura del sòl, quantitat d'aigua disponible en el sòl, etc.

Transpiració: La transpiració és el fenomen que succeeix quan es vaporitza l'aigua líquida que contenen els teixits de les plantes. Majoritàriament les plantes perden aigua pels estomes, que són obertures en les fulles de la planta per les quals travessen els gasos i el vapor d'aigua cap a l'atmosfera. L'aigua que es vaporitza prové del terra una vegada les arrels l'han absorbida, i així, passant per la planta, acaba evaporant-se aquesta. La major part de l'aigua que s'extreu del sòl es veu convertida en vapor d'aigua i alliberada a l'atmosfera, ja que només una petita quantitat acaba formant part dels teixits vegetals.

El procés de transpiració depèn també de la radiació solar, la temperatura, la pressió de vapor i de la velocitat del vent. Però a més, aquesta vegada, a diferència de l'evaporació, el sòl i les seves característiques influeixen en la transpiració. Així doncs, la salinitat, la textura i la capacitat de conducció d'aigua en el sòl, d'entre altres, seran aspectes que modifiquin la taxa de transpiració. A més, les característiques del cultiu, el medi on es treballa, les pràctiques del cultiu i el seu estat de desenvolupament, també s'han de considerar a l'hora d'avaluar la transpiració.

A la Figura 1 es representen les diferents variables que influeixen en l'evapotranspiració.




Figura 1: Factors que afecten l'evapotranspiració FAO-56 (Allen et. al. 1998)

El conjunt d'aquests dos processos s'anomena evapotranspiració. La conjunció d'aquests dos fenòmens ocorre simultàniament. No és fàcil distingir entre els dos processos, ja que dependrà de molts de factors i etapes del cultiu.

Per exemple, depenent de l'estat fenològic en que es trobi el cultiu, la quantitat d'ombra que projecta aquest sobre el terra variarà, la radiació ja no incidirà en la mateixa fracció de sòl i, per tant, l'evaporació d'aigua en el sòl es veurà modificada. Així doncs, en etapes primerenques on el cultiu no proporciona cobertura a la terra enfront de la radiació, el fenomen amb més pes serà l'evaporació. En canvi, en un cultiu que disposi d'una gran superfície d'ombreg cap al sòl, el fenomen prioritari dins de la evapotranspiració serà el de transpiració. Degut a això, es difícil comparar dades entre diferents cultius, condicions climàtiques, localitats, etc.

L'evapotranspiració s'expressa normalment en mil·límetres (*mm*) per unitat de temps. Aquesta mesura, ens serveix per expressar la quantitat d'aigua perduda en la superfície de cultiu en unitats de altura d'aigua, ja que *mm* d'aigua és igual a L/m^2 . En quant al temps transcorregut per referenciar aquesta mesura, pot ser d'una hora, d'un dia, setmanal, mensual, etc.

Aquesta mesura també es pot expressar en termes d'energia necessària, calor latent de vaporització λ , per evaporar la quantitat d'aigua evapotranspirada. D'aquesta manera, a una temperatura de 20°C, λ té un valor proper a 2.45 MJ Kg^{-1} . Per tant, el valor d'evapotranspiració en aquest cas es representaria en $\text{MJ m}^{-2} \text{ dia}^{-1}$.

1.2 Tipus d'Evapotranspiració

El concepte d'evapotranspiració inclou tres definicions diferents les quals venen definides per certes condicions de cada una d'elles.

1.2.1 Evapotranspiració del cultiu de referència ET_0

L'evapotranspiració del cultiu de referència es un paràmetre relacionat amb el clima que expressa la capacitat que té l'atmosfera per a evaporar sense restriccions d'aigua. Aquest poder d'evaporació ve relacionat amb una superfície de referència, que es correspon a un cultiu hipotètic de gespa amb unes certes característiques.

Aquest concepte ens ajuda a referenciar la capacitat d'evaporació de l'atmosfera independentment del cultiu, del maneig que es faci d'aquest, o del seu sòl, ja que degut a que l'aigua és abundant, les condicions del sòl i les seves característiques no intervenen, com es veu a la Figura 2.

Així, el valor d' ET_0 ens permet relacionar els valors d'evapotranspiració a altres superfícies. A més, es pot mesurar la capacitat evaporant de l'atmosfera en diferents localitats, ja que la mesura es pot efectuar en una superfície de les mateixes característiques en diferents zones.

D'aquesta manera, ET_0 està relacionat amb paràmetres climàtics. Així, podem dir que al no considerar ni el sòl ni el cultiu per al seu càlcul, i la seva capacitat posterior de extreure valors referenciats a altres cultius, és una bona eina per estimar l'evapotranspiració en una localitat i època de l'any.



Figura 2: Evapotranspiració de referència (ET_0) FAO-56 (Allen et. al. 1998)

1.2.2 Evapotranspiració del cultiu sota condicions estàndard ET_c

Aquest concepte d'Evapotranspiració del cultiu sota condicions estàndard és l'evapotranspiració que presenta qualsevol cultiu sense malalties, amb bona fertilització, en parcel·les extenses, baix condicions de sòl i aigua propícies on s'aconsegueix la màxima producció d'acord amb les condicions climàtiques que es presenten.

La evapotranspiració de cultiu es pot calcular a partir del valor de ET_0 multiplicat amb un coeficient extret experimentalment. Degut a la falta d'informació pels diferents cultius, no hi ha uns paràmetres que es puguin relacionar directament amb una fórmula per extreure'l directament com a tal.

Així doncs , la relació entre ET_c/ET_0 es pot extreure experimentalment , i així obtenir el coeficient , K_c , conegut com a coeficient de cultiu.

Així i tot , aquest valor de ET_c varia segons propietats aerodinàmiques, albedo i altres factors, tot i estant baix les mateixes condicions climàtiques. A més a més , el valor d'aquest coeficient variarà també segons l'estat fisiològic del cultiu, ja que en el moment de la sembra la influència d'una planta en el valor de l'evapotranspiració de cultiu serà diferent a quan esta en època de collita , on el seu desenvolupament vegetatiu sol es superior.




Figura 3: Evapotranspiració del cultiu sota condicions estàndard (ET_c) FAO-56 (Allen et. al. 1998)

1.2.3 Evapotranspiració del cultiu sota condicions no estàndard $ET_{c aj}$

Com hem vist anteriorment , les condicions descrites com “estàndard” difícilment son les que es tenen a la realitat. Sota condicions de camp, poden intervenir altres factors generalment no desitjats com ara elevat nivell de salinitat en el sòl , presència de plagues i malalties , baixa fertilitat , creixement de plantes no desitjades, menor densitat de plantes etc. Aquestes alteracions poden influir en el valor de la evapotranspiració i tenir valors d'evapotranspiració diferents del que estimariem amb ET_c .

Per tant , l'evaporació del cultiu sota condicions no estàndard, $ET_{c aj}$, es calcula utilitzant un coeficient de cultiu, K_c ajustat per diferents condicions d'estrès i limitacions que es presentin. Una altra opció es ajustar ET_c , amb un altre coeficient , K_s , que introdueix l'efecte d'estrès hídric que es tingui.

Actualment els valors dels coeficients per a ajustar l'evapotranspiració i obtenir $ET_{c aj}$ es poden obtenir en taules , segons el cultiu i les condicions reals que es tenen , enlloc de les estàndard definides per ET_c .



Figura 4: Evapotranspiració del cultiu sota condicions no estàndard ($ET_{c\ aj}$) FAO-56 (Allen et. al. 1998)

1.3 Estimació de l'evapotranspiració

Per determinar el valor de la evapotranspiració hi ha diferents mètodes: directes i indirectes. Els mètodes directes o experimentals necessiten mesures molt precises amb aparells específics, fet que normalment comporta un alt cost econòmic i que sigui difícil d'automatitzar. Tot i així, aquests mesuraments ens serveixen de forma general per a avaluar la eficàcia dels mètodes indirectes, que calculen l'evapotranspiració de forma teòrica a partir d'altres variables.

1.3.1 Mesures experimentals de l'evapotranspiració

Hi ha diferents mètodes experimentals per a calcular l'evapotranspiració :

Balanç d'energia i micro-climàtics: Son mètodes que es basen en mesurar els diferents fluxos d'energia amb el principi de conservació d'energia, sabent que l'energia que arriba a la superfície ha de ser igual a l'energia que surt de la superfície en el mateix període. D'aquesta manera, i sabent que la base de l'evaporació de l'aigua es la necessitat d'aportar energia, s'extreu el valor d'evapotranspiració.

Balanç d'aigua en el sòl: Aquests mètodes mesuren i avaluen els fluxos d'aigua que entren i surten de la zona radicular d'un cultiu, en un període de temps concret. Calculant l'aportació en el reg i la precipitació en un cultiu, i mesurant variables com l'escorrentia, la percolació profunda, podem saber que la diferència entre l'aportat i el mesurat final, serà l'aigua que ha estat evaporada o ha transpirat la planta. Pot haver variables que no es puguin tenir en compte per la seva dificultat en obtenir-les, com el flux subsuperficial i la capilaritat. Encara així els valors extrets d'evapotranspiració poden ser mesurats amb certa exactitud.

Lisímetres: Aquest mètode inclou el control de les variables més difícils de mesurar, degut a que es basa en aïllar la zona radicular del cultiu en un volum, on es mesura el pes amb exactitud. Així doncs la precisió es molt més alta que amb els mètodes abans comentats. Encara així, el seu cost i la seva complexitat per a tenir una mesura acurada limita el seu ús.

1.3.2 Models matemàtics per a l'estimació de l'evapotranspiració

Degut als impediments que presenten els sistemes de mesura d' ET_0 experimentals, s'han desenvolupat diferents equacions i models matemàtics que estimen l'evapotranspiració de referència a partir de paràmetres climàtics que afecten directa o indirectament a l'evapotranspiració. Alguns d'aquests mètodes necessiten ajustar-se segons en quina zona climàtica s'apliquin, o no es poden aplicar molt enllà d'on es varen calibrar.

El 1998 la FAO (Food and Agricultural Organization of the United Nations) va establir que l'equació de Penman Monteith (PM) fos el mètode estàndard per al càlcul de l'evapotranspiració de referència i la validació d'altres models (Allen, Pereira, Raes, Smith, i Ab, 1998). Però l'equació de Penman Monteith requereix moltes dades climàtiques que no solen estar disponibles o no són fiables en moltes estacions, fet que limita la seva utilització.

Aquesta limitació ha evidenciat la necessitat de models i fórmules que necessiten de pocs inputs climàtics, com l'equació de Hargreaves (Hargreaves i Samani, 1985), que només necessita dades mesurades de temperatura mitja, rang tèrmic i radiació extraterrestre calculada. L'equació de Hargreaves (HG) ha estat utilitzada i avaluada donant bons resultats i una precisió en el càlcul considerable, sobretot si s'ajusta a la zona climàtica on s'està aplicant. Tot i així, diferents estudis han conclòs que la seva precisió no és recomanable per a períodes de menys de cinc dies, degut a que es poden produir errors en l'estimació de la Et_0 diària causats per moviments de fronts meteorològics i per grans variacions en la velocitat del vent i de la cobertura de núvols (Hargreaves i Allen, 2003).

Aquesta equació és susceptible de ser calibrada i depenent del clima o de la zona geogràfica on ens trobem, es recomanable la utilització de coeficients correctors per ajustar el resultat obtingut, fet que no sempre comporta una millora en el càlcul, sobretot per coeficients d'ajustament de períodes de temps extensos.

Com alternativa als models convencionals, les xarxes neuronals artificials (ANN, artificial neural network) s'han aplicat amb èxit per estimar l' Et_0 als darrers anys.

Les ANNs són models simplificats inspirats en el sistema nerviós central, que actuen a mode de processadors distribuïts massivament basats en simples unitats de processament. Aquest sistema té capacitat de emmagatzemar el coneixement experimental obtingut i així poder utilitzar-lo (Haykin, 1999), en aquest cas per al càlcul de la Et_0 .

Les xarxes neuronals són capaces de detectar propietats molt més complexes de les dades d'estudi que tècniques tradicionals d'estadística, degut a la seva estructura no lineal (Galvão et al., 1999).

1.4 Xarxes neuronals artificials

1.4.1 Nocions d'ANNs

El funcionament neuronal biològic consisteix en una xarxa on milions de neurones estan interconnectades. En la Figura 5 es representa una neurona i les seves parts. El sistema artificial pretén recrear el sistema biològic.

Les xarxes neuronals artificials estan formades per un nombre determinat de processadors, o neurones, disposats en varies capes i interconnectats entre si mitjançant connexions a les que se els hi assigna un factor de ponderació o pes. D'aquesta manera, realitzen càlculs simples basats en la informació que reben de les neurones, o processadors veïns. Una de les característiques de les xarxes

neuronal es que no segueixen unes regles escrites, sinó que es basen en aprendre, on els pesos de les connexions que s'han assignat aleatòriament al principi ,es van ajustant progressiva i automàticament , per a poder resoldre el problema en qüestió.

D'aquesta manera, les xarxes neuronals artificials es basen en adquirir coneixement gràcies a un entorn i a la capacitat d'aprenentatge, ajustant la força o pes de les connexions de les neurones entre sí. Així, una xarxa neuronal es veurà estimulada per l'entorn , aquests estímuls faran canviar els pesos




Figura 5: Esquema d'una neurona biològica (Wikimedia Commons)

de les connexions de les neurones, i es quan la xarxa neuronal es comportarà de manera diferent a com ho feia, ja que haurà adquirit coneixement, canviant els seus paràmetres interns.

Per això caldrà establir una arquitectura neuronal. L'arquitectura neuronal comprèn el nombre de neurones i capes ocultes que es definiran , per a llavors "entrenar" la xarxa o model , amb dades de entrenament o aprenentatge. Aquestes dades d'aprenentatge hauran de ser representatives i significatives.

1.4.2 Evolució de les ANNs

El 1943 , es va produir el primer intent per explicar el funcionament del cervell humà (McCulloch y Pitts), com a una xarxa de cèl·lules interconnectades entre sí. No va ser fins el 1949 , quan es va proposar que aquestes xarxes artificials eren capaces d'aprendre, ja que aquest fet estava relacionat amb la conductivitat de la sinapsis. Quan una neurona era activada repetidament per una altra a través d'una sinapsis determinada , augmentava la seva conductivitat, fet que acabava induint a la formació d'un circuit de neurones estretament connectades entre sí (Hebb,1949).

El 1951 es creà la primera màquina de xarxes neuronals , amb 40 neurones , que imitava el cervell d'una rata. Més tard , es presentà "Perceptron" , que presentava tres tipus d'unitats; sensors , unitats d'associació i unitats de resposta. El "Perceptron" es la xarxa neuronal més antiga amb capacitat de generalitzar després d'haver passat per un procés d'aprenentatge.

Dos anys mes tard, es crea "Adaline" , la primera xarxa neuronal per a solucionar un problema real , com era l'aplicació de filtres adaptatius per a eliminar ecos a les línies telefòniques.

Més tard, una nova tècnica d'aprenentatge , denominada retropropagació de l'error, impulsà encara més la seva utilització fins a l'actualitat, on les seves aplicacions s'han introduït a diferents camps.

1.4.3 Aplicacions de xarxes neuronals a diferents camps

Avui en dia és amplia la bibliografia que presenta resultats de xarxes neuronals aplicades a diferents àmbits com finances (per a detecció de frau , interpretació de firmes), medicina (amb anàlisi d'imatges , causalitat d'atacs epilèptics), en el transport (útil per l'optimització de rutes , distribució de recursos) i en molts més àmbits. La seva raó per a l'aplicació en múltiples situacions és la capacitat per reconèixer patrons no lineals, com ja havíem comentat anteriorment, fet que converteix a les xarxes neuronals en una versàtil eina.

En l'àmbit de l'agricultura, són nombrosos els estudis aplicats de xarxes neuronals, per exemple:

- Anàlisi d'imatges de productes agrícoles mitjançant xarxes neuronals (D.D. Jayas, J. Paliwal , N.S. Vison 2004). Degut a que la forma dels productes agrícoles no esta governada per cap funció matemàtica , l'ús de xarxes neuronals pot ser funcional per a analitzar imatges d'aquests i classificar-los
- Predicció del rendiment de cultiu (Snehal S.Dahikar , Sandeep V.Rode, 2004)
- Estimació de contingut hídric del sòl (Martí et al., 2012)
- Estimació de precipitació a partir d'imatges satèl·lit (Islam i Kothari, 2000)
- Disseny hidràulic de reg (Shayya and Sablani 1998, Martí et al., 2010b)

1.4.4 Utilització d'ANNs en el càlcul d' E_{t_0}

A l'actualitat hi ha molts d'estudis sobre el l'estimació de l' E_{t_0} (Sudheer et al. 2003; Kumar et al. 2008; Landeras et al. 2008; Kisi 2007; Kisi Ö and Cimen 2009), però la seva similitud amb l'estudi es destaquen només els següents:

-Zanetti et al. (2007): Utilitzaren xarxes neuronals per estimar els valors d'evapotranspiració de referència calculats amb l'equació de la FAO-56 PM , a partir de valors màxims i mínims de temperatura , radiació extraterrestre i hores de llum diàries.

-Martí i Gasque (2010): Utilitzà models de xarxes neuronals per al càlcul de l'evapotranspiració considerant inputs locals i inputs auxiliars exògens d'estacions veïnes, incorporant també l'avaluació externa dels models entrenats.

-Marti et. al. (2011): Aquest estudi analitza la capacitat d'un model neuronal entrenat amb temperatura màxima , mínima , radiació extraterrestre teòrica i hores de llum diàries. Aquest estudi considera per primera vegada un procés d'avaluació robust en models d' E_{t_0} , l'avaluació per parts. Així, es repeteix el procediment entrenament-test fins avaluar el set de dades al complet.

1.5 Objectius del treball

Aquest estudi presenta els següents objectius:

-Implementar diferents models neuronals per estimar l'evapotranspiració de referència a les Illes Balears.

-Proposar models neuronals artificials basats en poques variables d'entrada com a alternativa a models convencionals existents.

-Aplicar un procediment robust de validació dels models, la validació per parts, com alternativa al mètode hold-out, habitual en la pràctica.

-Aplicar Matlab per a dur a terme tots els procediments estudiats.

2	Mètodes.....	19
2.1	Dades utilitzades.....	19
2.2	Càlcul de targets.....	20
2.3	Aplicació de xarxes neuronals artificials	21
2.3.1	Funcionament de la xarxa i el seu entrenament	21
2.3.2	Error avaluat a l'entrenament.....	23
2.3.3	Funció de transferència	23
2.3.4	Algoritme d'aprenentatge.....	23
2.3.5	Criteri d'aturada de l'aprenentatge	23
2.3.6	Partició de dades.....	24
2.3.7	Arquitectura òptima.....	26
2.3.8	Inputs considerats.....	26
2.3.9	Models neuronals implementats.....	27
2.4	Fórmules empíriques	27
2.4.1	Equació original de Hargreaves.....	27
2.4.2	Equació de Hargreaves i Samani	28
2.4.3	Equació de Valiantzas.....	29
2.4.4	Ajust de les fórmules empíriques	29
2.5	Avaluació dels models.....	29
2.6	Implementació amb Matlab.....	30

2 Mètodes

2.1 Dades utilitzades

Les dades utilitzades per a aquest estudi han estat extretes de 12 estacions meteorològiques del Sistema d'Informació Agroclimàtica pel Regadiu (SIAR).



Figura 6: Mapa de les estacions del SIAR

Les dades recopilades inclouen temperatures màximes, mínimes i mitjanes diàries, humitat relativa, radiació solar i dades de velocitats del vent, entre d'altres. A més a més, inclou valors d' Et_0 diària, segons el mètode de la FAO-Penman Monteith.

De cada estació s'ha extret el màxim de dades possibles, així que cada estació té diferent nombre de dades totals, degut a que no totes han estat recol·lectant informació des del mateix moment, i no totes segueixen en actiu.

El període corresponent a les dades utilitzades així com les dades geogràfiques de les estacions considerades en l'estudi es troben a la Taula 1. Les dades d'aquestes estacions poden ser considerades normals des d'un punt de vista climàtic, ja que no ens trobem davant anys amb fluctuacions dràstiques de les variables. De totes maneres, s'han descartat les dades de variables fora del rang de ± 3 pics el valor mitjà.

Nombre	Estacions	Període disponible	Dies Totals	UTM X	UTM Y	Altitud (m)
1	Artà	2005-2017	4022	1045510	4413540	114
2	Calvià	2005-2017	3999	969620	4392240	20
3	Ciutadella	2008-2009	240	1085510	4446460	21
4	Eivissa S'estany	2005-2017	3957	882360	4295680	11
5	Es Mercadal	2005-2017	4142	1106140	4452380	41
6	Felanitx	2004-2017	4786	1023670	4387260	109
7	Inca	2004-2017	4784	1009420	4409550	42
8	Manacor	2004-2017	4764	1030470	4395600	84
9	Santa Eulàlia	2004-2017	4631	884487	4327280	130
10	Sa Pobla	2004-2017	4756	1017420	4423370	6
11	Sóller	2004-2012	2878	989206	4419030	44
12	Son Ferriol	2004-2017	4704	992040	4394870	28

Taula 1: Dades de les estacions

A la Taula 2 Taula 2: Valors mitjans de diferents variables de les estacions es presenten els valors mitjans de diferents variables mesurades per les estacions. A continuació la Taula 3 mostra les desviacions estàndard de cada variable per cada estació

Estació	Temp Mitjana (°C)	Temp Max (°C)	Temp Mínima (°C)	Humitat Mitjana (%)	Humitat Max (%)	Humitat Min (%)	Vel. del vent (m/s)	Vel. del vent Max (m/s)	Radiació (MJ/m2)	Radiació extraterrestre calculada(MJ/m2)
1	16.37	22.38	10.76	76.20	95.03	49.57	0.80	4.58	15.60	28.30
2	16.73	22.97	10.59	75.24	94.22	48.82	1.02	5.04	15.63	28.09
3	16.09	20.17	11.63	76.07	92.68	54.84	2.11	6.69	18.07	30.09
4	18.54	21.82	14.99	75.35	90.00	57.56	2.52	6.83	16.91	28.45
5	17.16	22.33	11.81	74.83	93.05	51.16	1.14	5.38	15.31	28.53
6	17.13	23.56	11.33	74.15	93.97	46.00	0.98	5.30	16.27	28.76
7	16.78	23.61	10.22	73.46	94.60	44.71	1.66	6.36	16.80	28.71
8	16.67	23.16	10.23	74.91	94.70	46.80	1.66	6.48	16.54	28.77
9	17.07	23.14	10.92	74.86	94.95	47.44	1.41	6.08	16.78	29.32
10	16.50	23.65	9.28	76.08	95.62	47.70	1.28	6.04	16.04	28.70
11	17.20	23.10	11.73	72.48	92.32	46.15	0.45	3.74	13.85	28.36
12	17.47	23.67	11.53	74.15	92.90	47.72	1.09	5.08	16.12	28.75

Taula 2: Valors mitjans de diferents variables de les estacions

Estació	Temp Mitjana (°C)	Temp Max (°C)	Temp Mínima (°C)	Humitat Mitjana (%)	Humitat Max (%)	Humitat Min (%)	Vel. del vent (m/s)	Vel. del vent Max (m/s)	Radiació (MJ/m2)	Radiació extraterrestre calculada(MJ/m2)
1	5.89	6.64	5.60	10.27	5.39	13.75	0.46	1.48	7.91	10.06
2	5.80	6.36	5.71	10.35	6.04	13.34	0.48	1.95	7.77	10.01
3	6.23	6.99	6.06	9.42	5.71	14.76	1.02	2.17	8.94	10.73
4	5.14	5.67	5.08	9.31	7.35	12.43	1.20	2.20	8.10	9.92
5	5.83	6.73	5.55	9.60	5.59	13.22	0.76	1.78	8.25	10.12
6	6.38	7.06	6.10	11.13	5.45	14.90	0.51	1.59	7.88	9.98
7	6.39	7.40	5.92	11.32	5.18	15.13	0.85	2.01	8.33	10.07
8	6.22	6.93	5.93	10.33	4.62	14.53	0.85	2.09	8.07	10.03
9	6.07	6.75	5.96	10.23	5.17	14.22	0.68	1.82	8.09	9.87
10	6.08	6.87	5.84	10.04	4.44	14.69	0.73	2.26	8.07	10.06
11	6.35	6.99	5.86	11.62	6.97	13.13	0.28	1.44	8.56	10.00
12	6.20	6.66	6.19	10.46	6.10	14.64	0.56	1.69	7.62	9.96

Taula 3: Desviacions estàndard de diferents variables de les estacions

2.2 Càlcul de targetes

L'aplicació de les ANNs requereix uns valors objectiu o targetes per entrenar i validar els models. Com hem dit anteriorment, les mesures d' Et_0 amb lisímetres són complexes i la seva instal·lació es costosa i difícilment susceptible d'automatitzar-se a les estacions. Es per això que les dades de Et_0 que s'utilitzen com a targete per entrenar els models neuronals estan calculats amb el model de la FAO-56 PM, ja que esta considerat com el mètode estàndard per al càlcul de l' Et_0 .

$$ET_0^{PM} = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma(1+0,34u_2)} \quad (1)$$

Com podem veure a l'equació (1), l'equació de PM ens dona el resultat en (mm/dia), on :

Rn= Radiació neta en la superfície del cultiu ($MJm^{-2} \cdot dia^{-1}$), G= fluxe de calor del sòl ($MJ m^{-2} \cdot dia^{-1}$), T= temperatura mitja de l'aire diària a 2-m de altura (°C); γ =constant psicomètrica (kPa/°C); Δ =pendent de la corba de la pressió de vapor (kPa/°C); e_s =pressió de vapor(kPa); e_a =pressió de vapor actual (kPa) i u_2 = velocitat del vent a 2-m de altura.

Encara que l'estació ja ens donava el valor de Et_0 amb el model de PM, s'ha procedit a calcular-ho de nou per comprovar el seu valor i, així, utilitzar-ho com a output de referència a l'entrenament de les xarxes neuronals, seguint el procediment d'Allen et al. (1998)

2.3 Aplicació de xarxes neuronals artificials

2.3.1 Funcionament de la xarxa i el seu entrenament

Com s'ha comentat a la introducció, el funcionament de les xarxes neuronals més habituals es basa en anar aprenent dels errors que es generen a partir d'uns inputs i un output de referència, per anar successivament reajustant els paràmetres del model.

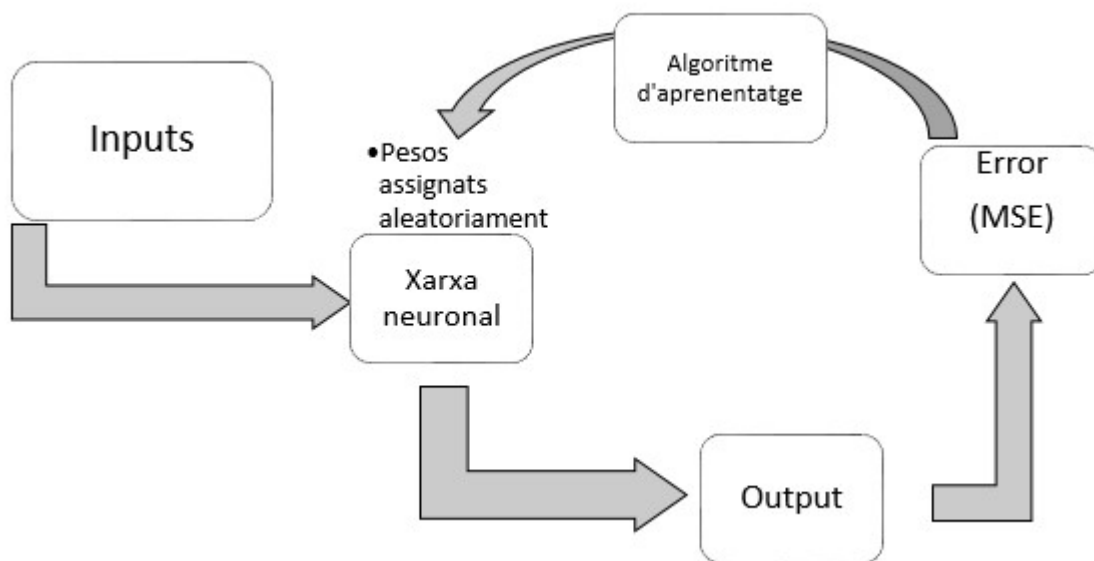


Figura 7: Funcionament de la xarxa neuronal

L'arquitectura d'una xarxa neuronal es compon d'una capa d'entrada, una o diverses capes ocultes i una capa de sortida, així com el nombre corresponent de neurones de cada capa.

Les xarxes neuronals que s'utilitzaran i s'entrenaran seguiran l'algoritme de retropropagació de l'error. La propagació cap enrere dels errors o la retropropagació és un mètode d'aprenentatge supervisat, utilitzat per a entrenar xarxes neuronals artificials.

Aquest mètode permet reajustar els pesos, assignats aleatòriament al principi, reduint l'error gradualment, iteració rere iteració, per aconseguir un error cada pic menor respecte a l'output assignat.

Els outputs generats per la xarxa es comparen amb els targets i es generen uns errors. Aquests errors es propaguen cap enrere per ajustar els pesos d'acord amb un algoritme que força una minimització de la funció d'error escollida, habitualment l'error quadràtic mitjà (MSE)

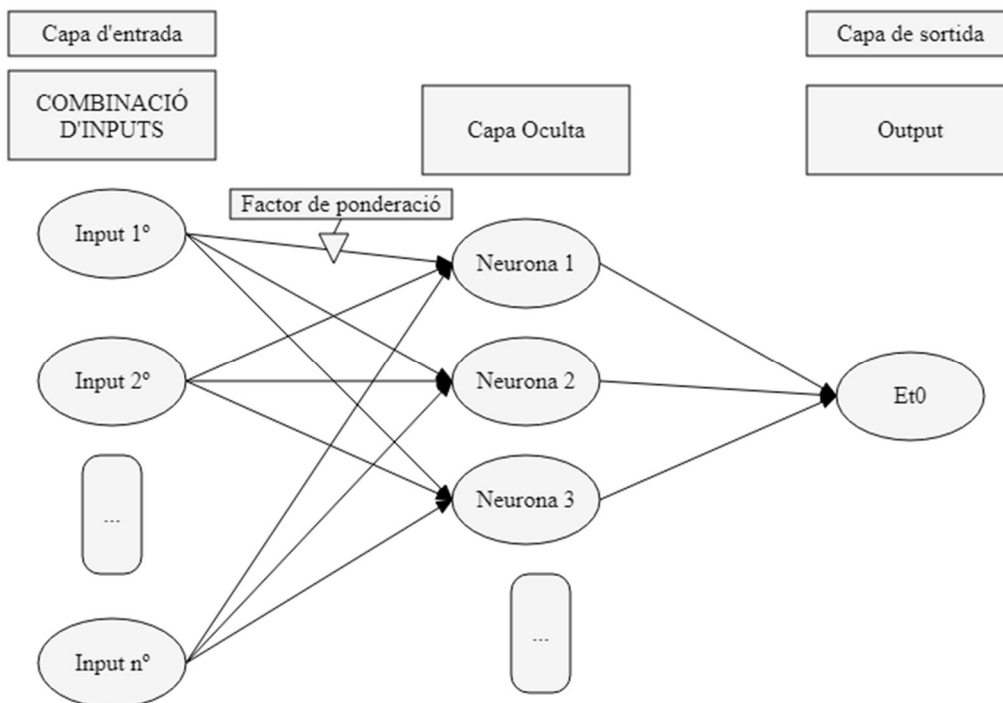


Figura 8: Esquema de les diferents capes de la xarxa neuronal

Totes les neurones de les xarxes neuronals utilitzades i disposades han utilitzat la configuració del model de Haykin (1999). Aquestes neurones segueixen les següents fórmules per a calcular els corresponents valors de sortida:

$$V_k = \sum_{j=1}^n W_{kj} * X_j + b_k \quad (2)$$

$$y_k = \varphi * (v_k) \quad (3)$$

On X_j , es la senyal de l'input, W_{kj} , es el pes sinàptic de la neurona k , v_k es el combinador lineal o unió de suma, b_k es el terme independent, o també anomenat "bias", y_k es l'output de la neurona i φ es la funció de transferència. A la Figura 9 es representa el funcionament en que es basen les neurones en qüestió.

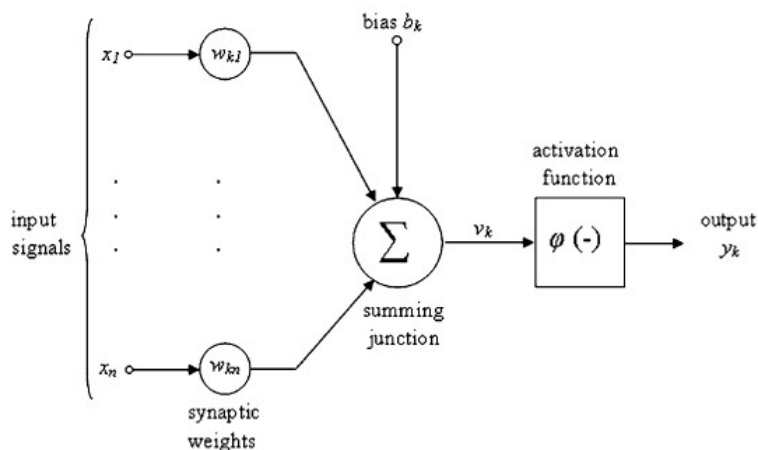


Figura 9: Configuració de les neurones aplicades (Martí et. al. 2010)

2.3.2 Error avaluat a l'entrenament

La funció d'error escollida per aplicar el criteri d'entrenament ha estat l'error quadràtic mitjà, o en anglès "Mean Square Error" (MSE). D'aquesta manera, es buscarà obtenir el mínim valor possible a l'hora de sumar els errors quadrats de les neurones de sortida. La fórmula per al càlcul del MSE es:

$$MSE = \frac{1}{N} \sum_{n=1}^N e(n) \quad (4)$$

On N es el nombre d'iteracions/patrons, i $e(N)$ es l'error comés per la xarxa per l' n -èsim patró, iteració, que ve donat per:

$$e(n) = \frac{1}{2} \sum_{i=1}^{nc} (s_i(n) - y_i(n))^2 \quad (5)$$

On $y_i(n)$ i $s_i(n)$ son els vectors de sortida de la xarxa i la sortida desitjada per l' n -èsim patró, respectivament.

2.3.3 Funció de transferència

La funció de transferència o activació pretén introduir no linealitat a la suma ponderada de cada neurona. En aquest estudi s'ha escollit la funció tangent sigmoïdal, \tanh , en detriment de la funció d'activació $\log\text{sig}$. Altres estudis previs sobre implementació de xarxes neuronals han utilitzat aquesta funció d'activació satisfactòriament amb sets de dades similars (Martí i Gasque 2010; Martí et al. 2010a, c).

2.3.4 Algoritme d'aprenentatge

L'algoritme escollit per reajustar els pesos del model neuronal ha estat el de Levenberg-Marquardt. Aquest mostra velocitats molt ràpides de convergència del mean square error (MSE), a pesar de la complexitat del seu càlcul. Aquest es calcula mitjançant la matriu Jacobiana dels errors de les neurones de sortida.

$$x_{k+1} = x_k - [J^T * J + \mu * I]^{-1} * J^T * e_k \quad (6)$$

On J es la matriu Jacobiana dels errors de les neurones de sortida, matriu on es troben les primeres derivades dels errors respecte als pesos. J^T és la trasposada de la matriu Jacobiana, I es la matriu identitat de la mateixa mida que la matriu Jacobiana, e es el vector d'errors de les neurones de sortida i μ es la constant que decreixerà en cada iteració en la que s'observi una reducció del MSE, o incrementada, on es descartaran els pesos actualitzats si el valor de MSE s'augmenta.

El software Matlab, utilitzat per a implementar les ANNs, ja té implementat aquest algoritme.

2.3.5 Criteri d'aturada de l'aprenentatge

Un dels problemes d'implementar un model neuronal és el fet que aquests models són dissenyats per funcionar en un àmbit molt concret, ja que les dades en les que es basen per aprendre son les donades en l'entrenament. Es a dir, en cada iteració que es produeix en l'estat d'entrenament, fa que el model s'emmotlli cada pic més a les dades donades, millorant la seva precisió, però perdent així la capacitat de generalitzar amb dades distintes.

En el present estudi , aquestes dades son extretes de diferents estacions com hem comentat abans, amb el seu propi clima ó microclima i les seves possibles tendències anuals. Aquest fet pot provocar que una vegada el model hagi estat entrenat no pugui extrapolar-se per altres estacions si s'ajusta el model a les dades d'entrenament en excés.

Per evitar aquest fenomen, anomenat sobreajust o sobreentrenament (overfitting), s'ha aplicat la tècnica d'aturada avançada (early stopping) junt amb l'algoritme d'aprenentatge.

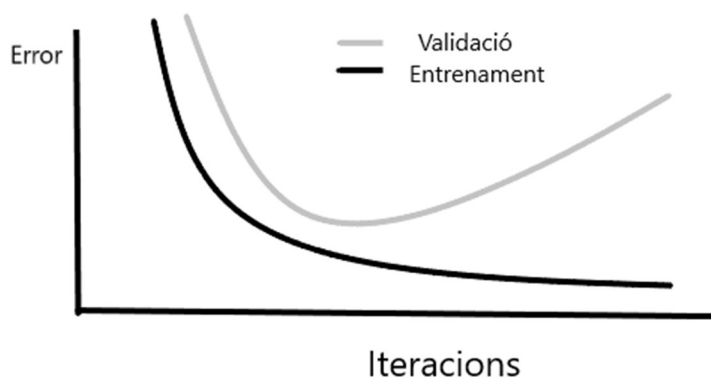


Figura 10: Criteri d'aturada de l'entrenament per validació

Aquest mètode, consisteix en separar una part del set de dades per controlar el grau de sobreajust, en el nostre cas un 15% de les dades d'entrenament i que anomenarem set de dades de validació creuada (cross-validation-CV). Aquest set de dades servirà d'indicador per a aturar el procés d'entrenament i evitar l'overfitting. D'aquesta manera s'avaluarà l'error, iteració rere iteració, en el set de dades de CV. Així doncs, quan l'error escollit per entrenar les xarxes i, en el nostre cas MSE, presenti un valor inferior a l'anterior iteració, es podrà seguir l'entrenament , reajustant els pesos i cercant una millora en l'error en la següent iteració. Si pel contrari , s'arriba a la iteració en que l'error donat en el set de CV es major que l'error donat en la iteració anterior , es dona per acabat l'entrenament.

D'aquesta manera, es controla que no s'ajusta en excés un model per a un set de dades. Per un altre banda , s'ha limitat el nombre d'iteracions en 100 per evitar una càrrega de temps excessiva , en els casos que l'error obtingut del set de dades de validació no augmenta.

2.3.6 Partició de dades

S'ha hagut d'escollir una tècnica per a decidir quines dades s'agafaven per a l'entrenament de la xarxa i quines per a testar la seva capacitat de generalització.

Normalment , una tècnica molt utilitzada en diferents estudis per a la validació de xarxes neuronals, es la tècnica de hold out (HO). Aquest mètode consisteix en fer una única partició del set de dades per entrenar i testar el model neuronal. El problema de l'ús d'aquesta tècnica és que pot dur a conclusions no representatives ó parcialment correctes, ja que l'avaluació de l'error només esta referida a un set de test limitat, el triat (aleatòriament) per a avaluar els errors. Aquest fet que no sempre pot arribar a ser representatiu (Martí et al., 2013; Martí et. al. , 2011).



Figura 11: Hold out

Un altra possibilitat seria utilitzar la tècnica de deixar un patró fora per testar, en anglès leave one out (LOO) . Aquesta tècnica consisteix en agafar un patró per testar el model que haurà estat entrenat amb la resta de patrons disponibles, i repetir el procés tantes vegades com patrons tingui el set de dades.

En el present cas, hi ha tants patrons com dies disponibles i s'entrenaria un nombre de models igual al nombre de dies disponibles. Per al càlcul de l'error, al final es fa la mitjana total dels errors obtinguts. Aquesta tècnica és efectiva i es sol utilitzar en set de dades on la quantia de dades és escassa. D'aquesta manera, es fa un entrenament més efectiu al deixar el màxim nombre de patrons possible per entrenar.

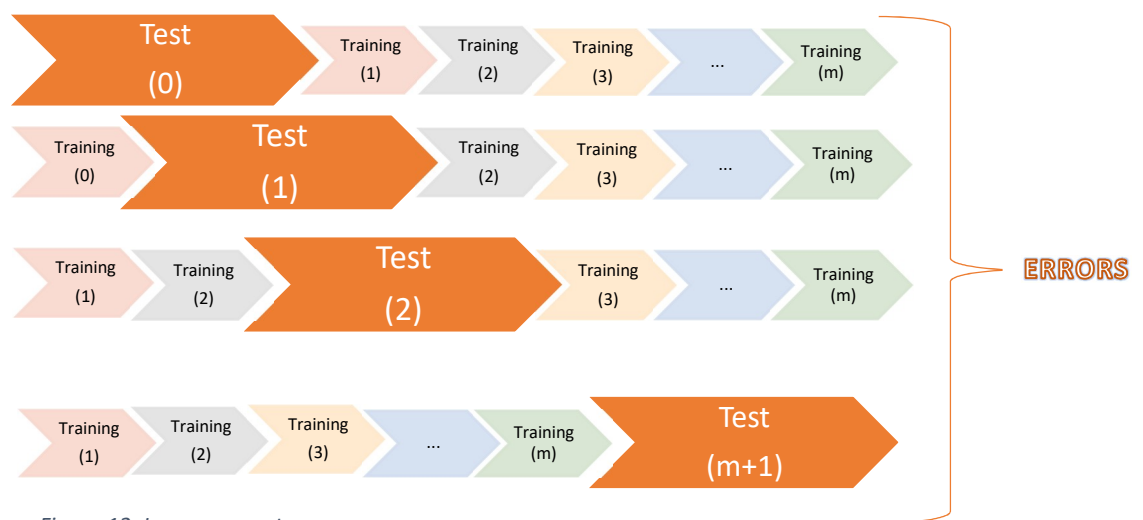


Figura 12: Leave-one-out

L'inconvenient d'utilitzar aquesta tècnica és el seu elevat cost computacional, derivat del gran nombre de models que podria ser necessari avaluar. En el nostre cas el sets de dades son molt amplis , fet que faria inassumible el temps de càlcul.

Per tant , l'estratègia utilitzada en aquest cas ha estat la de validació creuada (k-fold), on es divideix el set de dades en diferents particions. En cada partició, una part de les dades serviran per a l'entrenament i la part restant serà l'escollida en cada cas per a testar el model entrenat. És repeteix el procediment deixant en cada etapa una partició o conjunt de dades diferents per testar fins avaluar el set complet. Al final, l'error es calcula com la mitjana dels resultats de cada combinació. Aquesta selecció ens permet tenir un set de test diferents, ja que no només s'assigna un set de dades de test, com en el cas de hold out. Així s'evita arribar a uns resultats finals , on el set de dades de test pugui no ser representatiu , i oferir uns errors o un resultats que no es correspondrien amb la realitat. El leave-one-out és un cas particular de la validació per parts, on es fan tantes particions com patrons hi ha disponibles. Per a utilitzar aquesta tècnica , necessitem que els diferents grups en que dividirem el set de dades sigui representatiu.

Pel nostre cas, el set de dades va ser dividit en anys, i posteriorment, es varen fer tantes particions com anys tenia l'estació. Un any es reservava per testar, i els restants s'utilitzaven com a set de dades d'entrenament. En cada etapa es deixava un any diferent per testar.

Així, per aplicar les ANN cal definir, 3 matrius: una d'entrenament (Tr), una de validació (CV) i una de test (Te). Per aplicar la validació per parts, s'ha reservat en cada etapa un any per a testar. Amb les dades restants, s'ha definit una matriu aleatòriament amb el 15% de patrons per evitar el sobreentrenament i aturar-lo, i el 85% restant s'ha utilitzat per ajustar els pesos del model.

2.3.7 Arquitectura òptima

No hi ha cap criteri acceptat per definir la conformació o arquitectura òptima d'una ANN, i es sòl fer per prova i error de diferents configuracions.

En el present treball, enlloc d'aplicar la metodologia aplicada per Zanetti et al. (2007), on només es fixaren certes arquitectures amb un nombre fix de neurones per capa oculta, s'ha establert una sola capa oculta, i un nombre màxim de neurones de 10. Estudis previs (Kumar et al. 2002) han establert que una capa oculta és suficient per resoldre el problema de vinculació input-output. D'aquesta manera s'ha definit que el programa entreni xarxes neuronals des d'1 neurona fins a 10. Cada arquitectura es considerada un nombre de repeticions determinada per evitar l'efecte d'assignació aleatòria de pesos a l'inici de l'entrenament. Aquesta assignació aleatòria pot influir a la solució de l'entrenament. D'aquesta manera, es repeteix en aquest cas 10 cops el procés d'aprenentatge per cada arquitectura, per evitar aquest possible efecte desfavorable

S'han aplicat dos criteris de selecció d'arquitectura òptima. Per una banda es seleccionarà l'arquitectura amb menys error de validació i, per una altra, l'arquitectura que menor error de test presenti, comparant les dades obtingudes pel model neuronal amb les calculades amb Penman-Monteith.

És a dir, s'escolliran dos models del total d'entrenats: un el qual pugui tenir més capacitat de generalització, més conservador, el que presenti menor error de validació, i un altre amb el qual obtindrem els millors resultats pel set de dades considerat, el que presenta menor error de test.

2.3.8 Inputs considerats

A l'hora d'aplicar les xarxes neuronals, és necessari escollir correctament els inputs dels models i evitar la introducció de soroll al model. Anteriorment ja s'ha comentat que l'output és $l'Et_0$. En quant als inputs a considerar, s'han establert diferents combinacions d'inputs, és a dir, s'han entrenat diferents models. La raó d'entrenar diferents models, que consten cada un de diferents inputs, es que depenent dels paràmetres que es tinguin en compte, la xarxa neuronal pot establir més o menys correlació amb $l'Et_0$, i així estimar millor o pitjor aquest valor.

La selecció d'aquest inputs a més a més, no ha estat aleatòria, sinó que s'ha justificat a partir de diferents fórmules empíriques existents que ja proposen uns inputs concrets. Així, una vegada entrenats els diferents models es podrà comparar els models neuronals amb els seus respectius models empírics, degut a que requeriran de les mateixes dades per a l'estimació de $l'Et_0$. D'aquesta manera, es pot veure en la **Taula 4** les diferents combinacions d'inputs escollides.

Models neuronals i empírics			
Nom de la xarxa	ANN_{Rs}	ANN_{Ra}	ANN_{HR}
Nom del model empíric	HG_{Rs}	HG_{Ra}	HG_{HR}
Nº Inputs	2	4	5
Inputs	R_s , T_{mitja}	T_{max} , T_{min} , T_{mitja} , R_a	T_{max} , T_{min} , T_{mitja} , R_a , HR mitja
Output	ET_0	ET_0	ET_0

Taula 4: Models considerats en l'estudi i els seus respectius inputs

2.3.9 Models neuronals implementats

A manera de resum, aplicant la validació per parts, estem considerant per una part, tantes xarxes com anys tingui l'estació, a més de que per a cada estació es consideraran n arquitectures que dependran del nombre de neurones assignades (fins a 10). A la vegada, l'entrenament de cada arquitectura es repetirà r vegades (10 pics) i també cadascun d'aquests casos es dura a terme 3 pics per cada combinació d'inputs.

La Taula 5 presenta el balanç de models analitzats.

Estació	Anys	Neurones	Repeticions	Combinacions d'inputs	Total
1	13	10	10	3	3900
2	13				3900
3	2				600
4	13				3900
5	13				3900
6	13				3900
7	14				4200
8	14				4200
9	14				4200
10	14				4200
11	9				2700
12	14				4200
Total de models entrenats					43.800

Taula 5: Balanç de models neuronals considerats

2.4 Fórmules empíriques

Com s'ha comentat anteriorment, els inputs seleccionats en cada cas venen donats per les següents fórmules per a calcular l'evapotranspiració.

2.4.1 Equació original de Hargreaves

Hargreaves (1985) publicà una equació per predir la Et_0 basat només en dos paràmetres:

$$ET_0^{HG} = 0.0135R_s(T + 17.8) \quad (7)$$

On R_s es la radiació solar en $mm \text{ dia}^{-1}$, i T és la temperatura mitjana. En el nostre cas, R_s ja estava mesurada degut a que les estacions comptaven amb la capacitat de mesurar aquesta dada. De totes

maneres , la obtenció d'aquesta dada fa que aquesta equació necessiti un input que molts de pics no estarà disponible.

2.4.2 Equació de Hargreaves i Samani

Hargreaves i Samani (1982) van concloure que la fracció de radiació extraterrestre que passa a través de l'atmosfera i arriba a la superfície de la terra, que es la principal font de energia per la qual es produeix la evapotranspiració, es pot estimar amb la diferència de temperatura màxima i mínima . La relació és la següent, en un dia clar , oposa molt menys resistència a la radiació solar per a incidir al sol , i per tant la temperatura màxima es veurà incrementada, a la vegada que la temperatura per la nit serà mes baixa ,ja que la atmosfera no oposarà resistència a la radiació a sortir cap a l'exterior.

Occorrerà just el contrari en dies ennuvolats , la temperatura màxima serà menor , i la mínima serà major , ja que els núvols retindran major radiació. Així proposaren la següent fórmula:

$$R_s/R_a = K_t(T_{max} - T_{min})^{0.5} \quad (8)$$

On R_a en $mm \text{ dia}^{-1}$ és la radiació extraterrestre que pot ser calculada (Allen et al., 1998) o extreta de taules (Samani 2000). K_t es un coeficient empíric que assumeix diferents valors segons la regió on sigui de necessitat la seva aplicació.

Originalment es va fixar en 0.17 en regions semi-àrides , encara que més tard Hargreaves recomanà la utilització del valor 0.162 per regions interiors on domina grans masses de terra, i 0.190 per regions costeres on les masses de aire es veuen enormement influenciades per masses d'aigua properes.

Així doncs , basats amb l'equació original de Hargreaves (6), i l'equació que relaciona Radiació solar amb Radiació extraterrestre mitjançant temperatura màxima i mínima (7), Hargreaves i Samani (1985) desenvoluparen una equació que requeria només temperatura , el dia de l'any , i la latitud per a calcular E_t .

$$ET_0^{HGS} = 0.0135 * K_t * R_a(T + 17.8)(T_{max} - T_{min})^{0.5} \quad (9)$$

On el coeficient K_t es sol establir com a 0.17 , molts de pics, ja directament es substitueix la multiplicació de $0.0135 * K_t$ per 0.0023; T és temperatura mitjana diària en °C, T_{max} i T_{min} , temperatura màxima i mínima respectivament, també en °C i R_a en $mm \text{ dia}^{-1}$.

El càlcul de R_a , radiació extraterrestre , s'extreu d'Allen et al (1998) :

$$R_a = \frac{24*60}{\pi} G_{sc} * d_r [w_s * \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(w_s)] \quad (10)$$

On R_a es radiació extraterrestre en $MJ \text{ m}^{-2} \cdot \text{dia}^{-1}$, i en cas de necessitar en $mm \text{ dia}^{-1}$, es multiplica per 0.408, G_{sc} és la constant solar , $0.082 \text{ MJ m}^{-2} \cdot \text{min}^{-1}$, d_r distància relativa inversa Terra-Sol , w_s angle de radiació a la posta del Sol en radians , φ és la latitud sent positiu(+) en l'hemisferi nord i negatiu(-) en l'hemisferi sud i δ declinació solar en radians.

$$d_r = 1 + 0.033 * \cos\left(\frac{2\pi}{365} J\right) \quad (11)$$

$$\delta = 0.409 * \sin\left(\frac{2\pi}{365} J - 1.39\right) \quad (12)$$

On J és el dia julià.

$$w_s = \frac{\pi}{2} - \arctang \left[\frac{-\tan(\varphi)\tan(\delta)}{X^{0.5}} \right] \quad (13)$$

$$\text{On } X = 1 - [\tan(\varphi)]^2 [\tan(\delta)]^2 \text{ ó } X = 0.00001 \text{ si } X \leq 0 \quad (14)$$

2.4.3 Equació de Valiantzas

Valiantzas (2017) proposà una fórmula per estimar la radiació solar a partir de dades de humitat relativa (RH) solament, en la que radiació solar era proporcional a $(1 - \frac{RH}{100})^x$, on x es un exponent empíric. D'aquesta manera, s'arriba a la següent fórmula:

$$R_s = 0.338 * R_a * (T_{max} - T_{min})^{c2} * (1 - RH/100)^{c3} \quad (15)$$

On els coeficients $c2$ i $c3$, son coeficients empírics, que van ser calculats mitjançant un procés de calibració, on es concluí que; $c2 = 0.3$ i $c3 = 0.2$

On finalment, per equivalència, combinant la darrera fórmula comentada amb la de Hargreaves equació (6), s'extreu la següent equació per al càlcul d' Et_0 :

$$ET_0^{Hr} = 0.338 * 0.0135 * R_a * (T + 17.8) * (T_{max} - T_{min})^{0.3} * (1 - RH/100)^{0.2} \quad (16)$$

On R_a es la radiació extraterrestre en $MJ m^{-2} \cdot dia^{-1}$, T , T_{max} i T_{min} son temperatures, mitjana diària, màxima i mínima respectivament, en $^{\circ}C$, i RH, humitat relativa.

2.4.4 Ajust de les fórmules empíriques

Cal dir que les tres fórmules han estat ajustades amb uns coeficient AHC específics, calibrant els resultats obtinguts inicialment amb els de Penman-Monteith, amb un AHC distint per a cada estació i fórmula, mitjançant:

$$b = \sum_i \frac{Et0_{PM,i}}{Et0_{k,i}} \quad (17)$$

$$AHC = a * b \quad (18)$$

On $Et0_{PM,i}$ i $Et0_{k,i}$ es el valor de d'evapotranspiració diari, en $mm dia^{-1}$, on i representa el dia, k la fórmula que es pretén ajustar, per al càlcul de AHC i $a = 0.0023$ per a *Hargreaves* i $a = 0.0135$ per a *Hargreaves* i *Samani* i *Valiantzas*. Per tant, s'extreu un coeficient AHC, a partir de la mitjana de comparar els valors de referència amb els calculats amb les diferents fórmules amb els sets de dades total.

La raó del seu ajust és que les xarxes neuronals han estat entrenades amb un valor d' Et_0 local i, per tant, seria ventatjista pels models neuronals si es comparessin amb els models empírics sense calibrar.

2.5 Avaluació dels models

El rendiment dels models s'avaluaran amb diferents indicadors per avaluar la seva precisió, considerant els valors calculats d' Et_0 amb Penman-Monteith com a referència.

Els diferents indicadors que s'han tingut en compte son:

MSE – Mean Squared Error-Error quadràtic mitjà

Es el mateix indicador que s'utilitza com a funció d'error l'entrenament de les xarxes neuronals, com s'ha comentat abans. Ens dona un error absolut, i es calcula amb la següent fórmula:

$$MSE = \frac{1}{n} * \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (19)$$

RMSE- Root mean squared error-Error quadràtic relatiu mitjà

Aquest indicador es calcula dividint el l'arrel quadrada de l'error quadràtic mitjà per la mitjana del set de dades considerat.

$$RRMSE = \frac{1}{\bar{x}} \sqrt{\frac{1}{n} * \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (20)$$

MAE-Mean absolute error- Error absolut mitjà

L'error absolut mitjà representa la diferència entre la mitjana dels valors i la mesura x_i , dividit pel nombre de dades i . Aquest error depèn de l'ordre de magnitud de la variable.

$$MAE = \frac{1}{n} * \sum_{i=1}^n |x_i - \hat{x}_i| \quad (21)$$

R²-Coeficient de determinació

El coeficient de determinació es el quadrat del coeficient de correlació de Pearson. Aquest coeficient ens relaciona la variància de la variable Y segons la variable X. D'aquesta manera, valora la correlació lineal entre l'estimació del model estudiat i el de PM.

$$r^2 = \left(\frac{n \sum x_i \hat{x}_i - (\sum x_i)(\sum \hat{x}_i)}{\sqrt{n(\sum x_i^2) - (\sum x_i)^2} * \sqrt{n(\sum \hat{x}_i^2) - (\sum \hat{x}_i)^2}} \right)^2 \quad (22)$$

AARE- Average absolute relative error- Mitjana del error absolut relatiu

Aquest indicador presenta un valor de l'error relatiu corregint l'efecte de compensació derivat de les desviacions negatives de l'error.

$$AARE = \frac{1}{n} * \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \quad (23)$$

2.6 Implementació amb Matlab

El programa utilitzat per a dur a la implementació de tots els models considerats ha estat el software Matlab. Matlab es una eina de software matemàtic que ofereix un entorn de desenvolupament integrat amb un llenguatge de programació propi.

Per a que el programa integrat dins Matlab pogués entrenar les xarxes amb les dades de les estacions i de la manera que es volia, s'ha hagut de modificar l'estructura original de les dades. Així doncs, es va passar el format de les dades de les estacions a Matlab. Una vegada implementades al format corresponent de Matlab, es necessari donar a la base de dades certa estructura per definir tant l'estructura de k-fold, com per definir en cada cas els inputs d'entrada de la xarxa neuronal.

Per a dur a terme aquestes modificacions, s'han dissenyat certs programes, definits a la Taula 6: Programes implementats a Matlab

Nom	Funció	Inputs	Outputs	Pàgina annex
Depurades	Elimina files amb NaN i valors que sobrepassen 3 pics la desviació mitjana de les columnes que ens interessin	-Dades estacions -Vector fila amb les columnes d'interès	-Dades estacions filtrades -Dades eliminades	Error! No s'ha definit el marcador.
Mileni	Agafa el set de dades i resta 2000 a les columnes que corresponen a l'any. Així passem de tenir el format en mil·lenni en una única xifra. <i>Exemple: "2005" passarà a ser: "5".</i>	-Dades estacions	-Dades estacions	56
Ordena2	Divideix el set de dades de cada estació per anys. D'aquesta manera, tindrem els set de dades dividit per estacions, i a al vegada, cada estació dividida per anys.	-Dades estacions	-Dades estacions amb una estructura de : 1-Estacions 2- Anys	56
Combinacions3	Crea les combinacions de anys per a cada estació, per a preparar l'estructura "k-fold". Es a dir, cada combinació tindrà un any, que ens servirà com a any de test, i tots els altres junts, que en aquest cas ens serviran d'entrenament. Aquest programa només crea les combinacions, no les efectua, així que servirà de guia per al següent programa.	-Dades estacions	-Guia de combinacions a seguir.	56
Final	Es serveix de les combinacions extretes del programa anterior(Combinacions3) per a separar l'any de test de la resta d'anys. Tindrem tantes combinacions com anys de dades tingui cada estació.	-Dades estacions -Guia de combinacions a seguir	-Set de dades amb una estructura de: 1- Estacions 2- Combinacions anys 3-Any test /Anys entrenament	57
Validació4	Aquest programa agafa un tant per cent (%) de les dades de "training" per a fer el set de dades que servirà com a validació. Per tant, per cada combinació, tindrem -Un any separat per a test, un tant per cent de dades de "cross" validation i un altre de "training".	-Dades estacions -Percentatge de validació	Set de dades amb una estructura de: 1- Estacions 2- Combinacions anys 3-Any test /Anys entrenament/Validació	57
Inout5	Separa entre inputs i outoputs, ja que dins de cada set de dades de test, training i cross validations, necessitarem separar entre columnes de inputs i de outputs.	-Dades estacions -Columnes inputs, en forma de vector -Columna output	-Set de dades amb una estructura de: 1- Estacions 2- Combinacions anys 3-Any test /Anys entrenament/Validació 4-Inputs/Output	57
CONJUNT	Aquest programa va cridant els programes successivament per automatitzar el procés de filtratge de dades i de preparació de l'estructura necessària per a dur a terme l'entrenament de xarxes neuronals. Els programes son: <u>Mileni</u> , <u>Ordena2</u> , <u>Combinacions3</u> , <u>Final</u> , <u>Validació4</u> , <u>Inout5</u>	-Conjunt d'inputs necessaris per als programes necessaris	-Set de dades final amb l'estructura descrita a "Inout5"	Error! No s'ha definit el marcador.
Prova1	Es el programa principal, el que s'encarrega de entrenar les xarxes neuronals. Dins d'aquest programa s'inclouen diferents programes per acabar tenint el resultat final. L'ordre de seqüència que segueix aquestes: <u>-Filtre2</u> <u>-CONJUNT</u> <u>-Conversió de cel·les en "estructura" per al programa d'entrenament.</u> <u>-Entrenatesta1Talt</u> <u>-ANN1Talt</u>	-Dades estacions -Tant per cent de dades de "Cross Validation" -Numero de neurones màximes a entrenar -Nombre de repeticions -Vector amb les columnes d'inputs -Columna output -Funció d'activació	-Resultats finals: <ul style="list-style-type: none"> • Errors globals (Criteri de Validació) • Errors per estació(Criteri de Validació) • Errors globals (Criteri de Test) • Errors per estació (Criteri de Test) 	58

	<u>-Càlcul d'errors</u>	-Nombre de capes ocultes		
Hgp2	S'encarrega de calcular els valor d'Et0 amb les tres diferents fórmules. Per això , abans calcula la radiació extraterrestre , amb dades de les estacions , i de latitud. Un cop calculats els valor d'Evapotranspiració , s'encarrega de calcular els errors respecte PM. A més a més , també ajusta les equacions de Hargreaves de manera anual , extraient un coeficient AHC , per ajustar els resultats de cada una d'elles , i tornar a calcular els errors.	-Dades estacions -Latituds de cada estació	-Valors diaris d'Et0 amb les diferents fórmules per les diferents estacions. -Errors respecte PM -Valors diaris d'Et0 ajustats amb AHC, amb les diferents fórmules per les diferents estacions. -Errors dels valors ajustats respecte PM	61
Estandard	Calcula la mitjana de les variables climàtiques de les estacions i a la vegada calcula la desviació estàndard d'aquestes.	-Dades estacions	-Mitjanes de les variables i desviacions estàndard	63
Arq	Recopil.la les arquitectures seleccionades per els menors errors obtinguts	-Resultats de les xarxes neuronals artificials	-Nombre de neurones seleccionades en cada cas	63
Anydetest	Agafa els menors errors de cada any de test tenint en compta les diferents repeticions i arquitectures	-Resultats de les xarxes neuronals	-Menors errors per cada any de test per cada estació.	63
PMN-56	Calcula els valors d'Et0 a partir de la fórmula de PM-56	-Dades estacions -Dades geogràfiques de les estacions	-Valors diaris d'Et0	63

Taula 6: Programes implementats a Matlab

A mode de resum de la metodologia seguida, es presenta l'esquema de la Figura 13: Resum dels casos contemplats a l'estudi, on a partir de les dades de les estacions s'avaluaran els diferents models neuronals i empírics amb els valors d' Et_0 calculats amb Penman-Monteith.

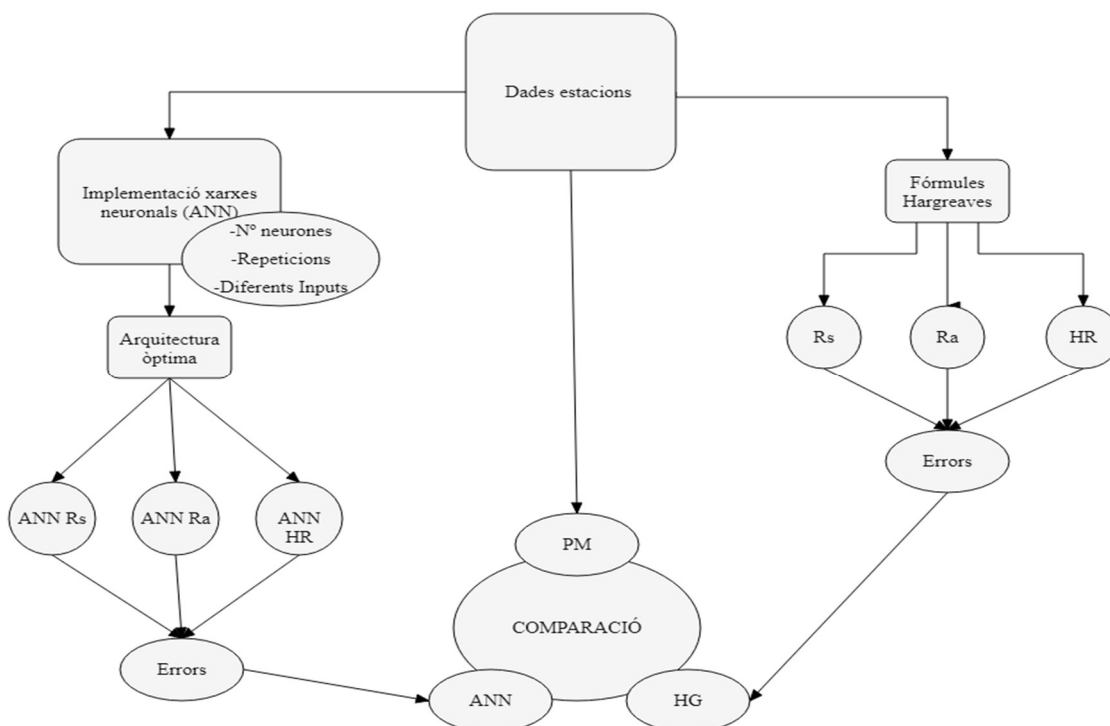


Figura 13: Resum dels casos contemplats a l'estudi

3	Resultats.....	34
3.1	Resultats globals	34
3.2	Resultats per estacions	35
3.3	Resultats per any de test	37
3.4	Selecció de l'arquitectura òptima	38
4	Conclusions	40

3 Resultats

3.1 Resultats globals

A la Taula 7 **Error! No s'ha trobat l'origen de la referència.** es presenten els indicadors globals mitjans dels models ANN_{RS} , ANN_{Ra} i ANN_{HR} , amb els dos criteris de selecció d'arquitectura òptima així com els corresponents models empírics calibrats i sense calibrar. Els indicadors presentats corresponen a la mitjana dels errors de cada any de test per a totes les estacions. D'aquesta manera observem el rendiment global a les Balears. S'ha exclòs l'estació 3 (Ciutadella). La raó d'excloure la estació 3 és que l'error en aquesta estació és molt superior a les altres, fet que desvirtuava la percepció del rendiment amb les altres estacions.

Aquest fet es deu a que l'estació 3 té molt poques dades diàries ,240 en total, en comparació a les altres estacions. Aquest fet implica que les dades tant d'entrenament , com les utilitzades per a testar el model poden no ser representatives, no ser suficients per a entrenar correctament els models neuronals. Degut a aquesta manca de dades seria més recomanable la utilització del leave-one-out en aquesta estació, ja que el cost computacional no seria tan gran, en comparació a les altres estacions , degut a la poca quantitat de dades. A més a més es podrien tenir més dades d'entrenament per entrenar el models i més sets de test ,que en l'actual cas.

Model		MSE	RRMSE	MAE	R2	AARE
Validació	ANN_{RS}	0.356	0.120	0.277	0.958	0.151
	ANN_{Ra}	0.493	0.166	0.357	0.919	0.164
	ANN_{HR}	0.401	0.136	0.282	0.946	0.115
Test	ANN_{RS}	0.339	0.114	0.261	0.961	0.144
	ANN_{Ra}	0.476	0.160	0.344	0.923	0.158
	ANN_{HR}	0.385	0.130	0.271	0.950	0.110
Sense ajustar	HG_{RS}	0.338	0.196	0.485	0.949	0.228
	HG_{Ra}	0.693	0.280	0.672	0.889	0.326
	HG_{HR}	0.381	0.204	0.461	0.924	0.211
Ajustats	HG_{RS}	0.398	0.205	0.506	0.949	0.231
	HG_{Ra}	0.378	0.202	0.468	0.889	0.222
	HG_{HR}	0.250	0.166	0.373	0.924	0.165

Taula 7: Resultats globals dels models neuronals i empírics

En quant als resultats globals, podem observar que la diferència entre els dos criteris de selecció d'arquitectura òptima no difereix gaire, així que podem dir que tant l'arquitectura amb menor error de validació i la de menor error de test es comporten de manera similar, encara que s'observa una lleugera millora amb el criteri de test.

Com podem observar, el coeficient R^2 és elevat en tots els models, el que implica una gran correlació lineal amb el model de PM-56. Respecte als diferents models neuronals, podem afirmar que el que mes error genera es el model ANN_{Ra} , ja que en tots els indicadors produeix un error més elevat que ens els altres dos models , ANN_{RS} i ANN_{HR} . Això pot ser degut a que la radiació extraterrestre ,a les Balears, no te tanta importància o influència en l'evapotranspiració com la radiació solar o la humitat relativa , ja que en els altres dos models són els inputs diferenciadors que s'han tinguts en compte. Podríem dir que la rellevància ,o la correlació de la humitat relativa i la radiació solar amb la

evapotranspiració es més gran que la radiació extraterrestre, que no es una variable mesurada sinó calculada.

Respecte als altres dos models restants , ANN_{RS} i ANN_{HR} , avaluar quins dels es comporta millor a l'hora d'estimar el valor d' Et_0 és més complicat, ja que segons els indicadors que es tenen en compte, un presenta més error que l'altre. En l'indicador AARE, error relatiu, podem afirmar que ANN_{HR} presenta millors resultats (0.110 vs 0.144 i 0.151 vs 0.115, segons el criteri de test i validació respectivament). Tot i així, en els altres indicadors l'error es menor en ANN_{RS} MSE (0.339 vs 0.385), RRMSE (0.114 vs 0.130) MAE (0.261 vs 0.271). Aquestes discrepàncies requereix una anàlisi per estació.

En quant als valors comparats de les xarxes neuronals i els models empírics calibrats i sense calibrar, podem veure que les xarxes neuronals obtenen un menor error, tant en errors absoluts i relatius en comparació amb els models empírics corresponents que utilitzen els mateixos inputs. Aquest fet inclou també els models empírics ajustats

En els models calibrats i sense calibrar , podem veure que no sempre es millora els errors, com es el cas del model de radiació solar HG_{RS} , MSE(0.338 vs 0.381), RRMSE(0.196 vs 0.204), MAE(0.485 vs 0.506) i AARE(0.228 vs 0.211). Aquest fet pot ser degut a que un sol factor de correcció per estació pot resultar molt general o poc precís. Segurament s'obtidria un menor error amb coeficients d'ajustament (AHC) per sets de dades temporals menors. Per exemple , coeficients d'ajust mensuals. Aquest fet ens mostra que no sempre es justifica la utilització de coeficients d'ajustament degut a que la millora no sempre es pot garantir, com hem vist en el cas del model HG_{RS} .

3.2 Resultats per estacions

A continuació es presenten dos gràfics, Figura 14 i Figura 15, amb els valors d'AARE i MAE per estació respectivament, segons els resultats obtinguts segons el criteri de test. Com hem dit anteriorment , l'estació numero 3 ens genera un error que dista molt dels altres, com es pot observar, degut a un conjunt de dades insuficient.

En aquests gràfics s'observa clarament que els errors, tant relatiu (AARE) com absolut (MAE) dels diferents models neuronals (símbols plens) son menors que en els dels models empírics, en totes les estacions , en excepció de l'estació 3.

En el gràfic de la Figura 14 podem veure que el model neuronal que millor es comporta en totes les estacions, excepte l'estació 3 que ja hem comentat amb anterioritat, és el ANN_{HR} .

Respecte als altres dos models, analitzant estació per estació, podem veure que a les estacions 4, 6 i 12 (Eivissa S'estany, Felanitx i Son Ferriol , respectivament) ens trobem que els models ANN_{Ra} i ANN_{RS} tenen errors pràcticament iguals. Inclús en algunes estacions veiem que es comporta lleugerament millor ANN_{Ra} que ANN_{RS} , a diferència del que havíem vist en els resultats globals. Comparant valors (AARE) de ANN_{Ra} i ANN_{RS} respectivament: (Estació 4: 0.1778 vs 0.1790 ; Estació 6: 0.1467 vs 0.1446 ; Estació 12: 0.1434 vs 0.1465) .

Per tant , degut a que el model ANN_{Ra} depèn de la temperatura, ja que la radiació extraterrestre es calculada ,els resultats analitzats ens podrien indicar que en les estacions mencionades, 4, 6 i 12, la correlació de temperatura amb evapotranspiració és elevada i similar a la dels altres dos models degut a la mínima diferència que hi ha entre els respectius errors.




Figura 14: Indicador AARE dels diferents models per estacions – Adimensional (-)

Aquests resultats ens mostren una lectura diferent a l'anterior que havíem fet amb els resultats globals per Balears, ja que la mitjana a Balears indicava que el model de radiació extraterrestre era el que obtenia valors més desfavorables. Així que encara que la tendència a les Balears sigui que el model ANN_{Ra} basat en temperatura, no estableixqui la mateixa correlació en el càlcul de l'evapotranspiració com els altres models, podem veure que no es així en la totalitat de les estacions. Dit d'una altra manera, en les estacions mencionades, podria ser suficient les dades de temperatura per a estimar l' ET_0 .

I respecte al model que té en compta la humitat relativa, ANN_{HR} , es confirma que en totes les estacions té més influència en l'evapotranspiració que les altres dues variables, radiació solar i radiació extraterrestre.

Respecte al gràfic de la Figura 15, la tendència observada als resultats globals es manté, obtenint errors absoluts, de mes baixos a més grans, de la següent manera: ANN_{RS} ANN_{HR} i finalment ANN_{Ra} .

Tot i així, podem observar a l'estació 4, Eivissa S'estany, que el model entrenat amb humitat relativa, genera un error absolut més baix, a diferència de la tendència global.




Figura 15: Indicador MAE dels diferents models per estacions – (mm/dia)

A l'annex a les taules 27-29 es presenta les diferents taules pels diferents models entrenats, amb els valors numèrics dels indicadors per estació. Cal dir que el terme Mitjana1 inclou totes les estacions, i la Mitjana2 exclou l'estació 3 degut a les raons abans comentades, i així no desvirtuar el rendiment global dels indicadors per a les Balears.

3.3 Resultats per any de test

A continuació, a la Figura 16 es presenten els indicadors amb els resultats dels diferents models neuronals a l'estació 1, amb els diferents errors (RRMSE) per any de test. Els errors mostrats són els menors errors obtinguts independentment de l'arquitectura, per el criteri de validació. A l'annex, es troba la Taula 16 on es troben els valors en que estan basats els gràfics en qüestió.




Figura 16: RRMSE per any de test a l'estació 1

Podem observar com el model que de manera general obté menors errors és el model ANN_{RS} . Després en ordre de millor a menor rendiment es, ANN_{HR} i ANN_{Ra} . Tot i així podem observar que els models ANN_{HR} i ANN_{Ra} en els anys de test 1 i 13, obtenen valors diferents a la mitjana global.

Respecte al model ANN_{HR} , veiem com a l'any de test 1 s'obté un error molt menor a la tendència global en els anys. De la mateixa manera ocorre a l'any de test 13 (0.019 i 0.039 per any 1 i 13, respectivament, vs la mitja de 0.121).

Respecte al model ANN_{Ra} , en l'any de test 1 s'obté un valor molt més baix a la mitjana anual. En l'any de test 13 d'aquest mateix model també ocorre el mateix, encara que amb un valor moderadament més alt. (0.04 vs 0.03, per any 1 i 13, respectivament; mitjana de 0.17). Aquest fet pot ser degut a que les dades de test d'aquests anys no son representatives, amb els inputs utilitzats en aquest cas.

Les diferències entre els models també sofreixen canvis, com es pot observar en l'any 2 i l'any 8. Encara que el rànking es manté, les diferències entre ells varien 0.080, 0.210, 0.188 per l'any 2 i 0.070 0.152i 0.111 per l'any 8, pels models, ANN_{RS} , ANN_{Ra} i ANN_{HR} respectivament.

Aquests fet ens evidencia la importància dels set de dades de test a l'hora de testar el model, ja que segons quin escollim, ens podria dur a conclusions equivocades o parcialment vàlides. A més, ens mostra la capacitat que té la partició de dades en subdivisions per a utilitzar la tècnica k-fold. Per tant,

la idea general de que els resultats (r anking) poden variar entre anys evidencia que el fet d'aplicar una t cnica de hold out, diferent a la utilitzada en l'estudi, podria portar a solucions parcialment v lides, com es podria veure en el cas de comparar els resultats de l'any 1 vs l'any 2. Tot i que en general el r anking es mant  constant entre anys (excepte anys 1 i 13), cal fer una validaci  per parts, la qual permet avaluar el set de dades al complet.

Tot i que aquests dos models mencionats varien en els anys de test 1 i 13, el model ANN_{RS} no pareix sofrir variacions en els anys de test comentats. Aquets fet pot ser degut a que la variaci  de l'input diferenciador, en aquest cas R_s , no sofreix un canvi significatiu en l'any de test, fet que permet al model neuronal estimar el valor d' Et_0 sense majors variacions en l'error que els altres anys.

A la Figura 17 es representen els valors de RRMSE per any de test de l'estaci  3. Podem observar que en els  nics dos anys de test, en el primer d'ell podem veure que s'obte un error molt inferior al segon any. Aquest fet ens podria indicar que en el segon any no es representatiu o no hi ha dades suficients per avaluar correctament les dades.

D'aquesta manera , l'error mitj  elevat a l'estaci  3 es deu al segon any, que desvirtua el rendiment dels models. De fet , si escollissim solament l'error en l'any de test 1, obtenim valors molt m s coherents i propers als obtinguts a les altres estacions, com es veu a les taules presentades a l'annex Indicadors desglossats per any de test 48.




Figura 17: RRMSE per any de test a l'estaci  3

3.4 Selecci  de l'arquitectura  ptima

En la Taula 8 podem observar la mitjana de nombre de neurones que han estat seleccionades pels dos criteris per a tots els anys de test i repeticions donades.

Podem observar que les arquitectures seleccionades segons el criteri de validaci  tenen m s nombre de neurones que segons el criteri de test. Per tant, degut a que el set de dades de validaci   s independent i el model no ha estat entrenat en base a aquestes, i que priori la capacitat de generalitzaci  es major, podem dir que un augment en el nombre de neurones permet crear models amb major capacitat de generalitzaci  en el nostre cas. A dem s , com hem comentat abans , la difer ncia d'errors entre els dos criteris de selecci  es m nima. Aquesta idea es contradiu amb l'idea te rica de que com menys neurones, m s capacitat te el model per a generalitzar. Aquest fet pot ser

degut a que el nombre de neurones total considerades (10) pot ser no suficientment ampli com per a establir aquesta relació en el present estudi.

Nombre de neurones ocultes						
Estacions	ANN_{RS}		ANN_{Ra}		ANN_{HR}	
	CV	Test	CV	Test	CV	Test
1	7.15	5.23	7.08	5.92	9.62	5.77
2	6.46	6.46	6.77	5.00	8.15	6.54
3	5.50	8.00	6.00	6.50	6.50	5.00
4	6.62	6.23	5.62	6.15	9.31	4.77
5	8.31	6.38	8.85	6.08	8.54	4.54
6	6.23	5.08	7.54	5.54	8.69	3.69
7	8.08	5.85	8.38	5.08	8.69	5.62
8	6.85	5.69	7.85	4.69	7.38	5.92
9	8.23	6.38	8.69	6.23	8.38	5.00
10	8.46	6.38	7.85	6.23	9.31	4.77
11	9.11	5.89	7.56	4.11	8.33	5.67
12	6.00	4.08	7.62	5.77	8.85	4.77
Mitjana	7.25	5.97	7.48	5.61	8.48	5.17

Taula 8: Nombre de neurones dels diferents models neuronals segons els dos criteris de selecció d'arquitectura òptima

A continuació es presenta la Figura 18 on es representa el criteri de selecció d'arquitectura òptima segons el criteri de validació en l'estació 1 i any de test 1. Podem veure que hi ha tres corbes: una que mostra l'error del set d'entrenament, una altra, de validació i l'altre, de test. Aquest gràfic representa la rutina per automatitzar la selecció de l'arquitectura òptima segons el criteri de validació. Així, com es veu en el gràfic, de totes les arquitectures possibles, s'agafen les repeticions amb els menors errors de validació, per llavors triar l'arquitectura que menor error de validació ha obtingut. Una vegada s'ha escollit arquitectura, els errors presentats i avaluats son els errors generats per aquella arquitectura amb les dades de test, que es veuria representada amb el punt corresponent de la corba d'error de test en el gràfic.

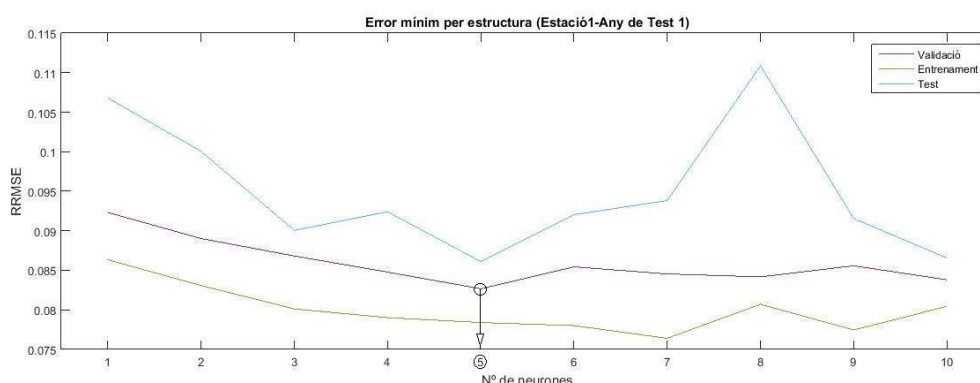


Figura 18: Selecció d'arquitectura òptima

4 Conclusions

Aquest estudi presenta l'aplicació de diferents models neuronals per estimar l' ET_0 a les Illes Balears amb validació per parts. Aquests models s'han comparat amb les equacions empíriques corresponents que utilitzen els mateixos inputs.

No només els models entrenats son capaços d'estimar el valor d' ET_0 amb un grau d'error acceptable, sinó que a més a més han donat unes estimacions amb un error per davall dels models empírics homòlegs. La millor combinació d'inputs correspon al model ANN_{HR} segons l'indicador AARE.

En quant a la utilització la validació per parts, s'ha evidenciat la importància en els resultats finals segons el set de dades de test. Si el set de dades no resulta representatiu s'obtenen errors, i per tant conclusions, que poden no mostrar la capacitat real de les xarxes neuronals per estimar l' ET_0 . Per tant, d'aquesta manera es pot concloure que no utilitzar tècniques que contemplin diferents particions del set de dades, com el k-fold, pot conduir-nos a resultats no fiables o erronis.

5 Bibliografia

Allen RG, Pereira LS, Raes D, Smith M., 1998 “Crop evapotranspiration. Guidelines for computing water requirements”. FAO irrigation and drainage, paper 56. FAO, Rome.

Allen, R. G., Pereira, L. S., Raes, D., Smith, M., & Ab, W. 1998. Allen_FAO1998, 1–15. <https://doi.org/10.1016/j.eja.2010.12.001>

Bachour, R., Walker, W.R., Torres-Rua, A.F., McKee, M., 2013. Assessment of reference evapotranspiration by the Hargreaves method in the Bekaa Valley, Lebanon. *J.Irrig. Drain. Eng. ASCE* 139 (11), 933–938.

Galvão, C.O., Valenc, a, M.J.S., Vieira, V.P.P.B., Diniz, L.S., Lacerda, E.G.M., Carvalho, A.C.P.L.F., Ludemir, T.B., 1999. *Sistemas inteligentes: Aplicac, ões a recursos hídricos e ciencias ambientais*. Universidade Federal do Rio Grande do Sul/Associaç, ão Brasileira de Recursos Hídricos, Porto Alegre, Rio Grande do Sul, Brazil.

Hargreaves, G.H., Allen, R.G., 2003. History and evaluation of Hargreaves evapotranspiration equation. *J. Irrig. Drain. Eng.* 129 (1), 53–63.

Hargreaves, G.H., Samani, Z.A., 1985. Reference crop evapotranspiration from ambient air temperature. *Appl. Eng. Agric.* 1 (2), 96–99. Kohavi, R., 1995. A study of cross-validation and bootstrap.

Haykin S., 1999 *Neural networks. A comprehensive foundation*. Prentice Hall International Inc., New Jersey

Kisi Ö ,2007 Evapotranspiration modelling from climatic data using a neural network computing technique. *Hydrol Process* 21:1925–1934

Kisi Ö , Cimen Ö 2009 Evapotranspiration modelling using suport vector machines. *Hydrol Sci J* 54(5):918–928

Kumar M, Raghuwanshi NS, Singh R, Wallender WW, Pruitt WO (2002) Estimating evapotranspiration using artificial neural network. *J Irrig Drain Eng* 128(4):224–233

Kumar M, Bandyopadhyay A, Raghuwanshi NS, Singh R., 2008 Comparative study of conventional and artificial neural networkbased ETo estimation models. *Irrig Sci* 26(6):531–545

Landeras G, Ortiz-Barredo A, López JJ., 2009 “Forecasting weekly evapotranspiration with ARIMA and artificial neural network models” . *J Irrig Drain Eng* 135(3): 323–334

Landeras G, Ortiz-Barredo A, Lo´pez JJ 2008., Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *Agric Wat Manag* 95(5):553–565

Martí P, Royuela A, Manzano J, Palau G., 2008b “Improvement of temperature based ANN models for ETo prediction in coastal locations by means of preliminary models and exogenous data”. Eighth international conference on hybrid intelligent systems 2008 proceedings, pp 344–349. *IEEE Xplore*

Martí, P., Shiri, J., Duran-Ros, M., Arbat, G., Ramírez de Cartagena, F., Puig-Bargués, J., 2013. Artificial neural networks vs. gene expression programming for estimating outlet dissolved oxygen in micro-irrigation sand filters fed with effluents. *Comput. Electron. Agric.* 99 (11), 176–185.

Martí, P., Juan Manzano Álvaro Royuela., 2011. Assessment of a 4-input artificial neural network for ET o estimation through data set scanning procedures, 181–195. <https://doi.org/10.1007/s00271-010-0224-6>

Martí, P., & Gasque, M. 2010. Ancillary data supply strategies for improvement of temperature-based EToANN models. *Agricultural Water Management*, 97(7), 939–955. <https://doi.org/10.1016/j.agwat.2010.02.002>

Martí, P., Shiri, J., Duran-Ros, M., Arbat, G., de Cartagena, F. R., & Puig-Bargués, J. (2013). Artificial neural networks vs. Gene Expression Programming for estimating outlet dissolved oxygen in micro-irrigation sand filters fed with effluents. *Computers and Electronics in Agriculture*, 99, 176–185. <https://doi.org/10.1016/j.compag.2013.08.016>

Miss. Snehal S. Dahikar, Dr. Sandeep V.Rode. Agriculture Crop Yield prediction using artificial Neural Network Approach Miss. Snehal S. Dahikar, Dr. Sandeep V.Rode.

N.S. Visen, J. Paliwal, D.S. Jayas and White N.D.G. (2004). Image analysis of bulk grain samples using neural networks.

Schultz, B., Thatte, C.D., Labhsetwar, V.K., 2005. Irrigation and drainage—main contributors to global food production. *Irrig. Drain.* 54 (3), 263–278.

Sudheer KP, Gosain AK, Ramasastri KS (2003) Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J Irrig Drain Eng* 129(3):214–218

Ortega Farias, S., Irmank, E., Cuenca, R.H., 2009. Special issue on evapotranspiration measurement and modeling. *Irrig. Sci.* 28 (1), 1–3.

Wilfredo Celestino Baldeón Quispe (2003) “Metodología de autocalibración para el modelo de simulación del acuífero”, (2003)

Zanetti SS, Sousa EF, Oliveira VPS, Almeida FT, Bernardo S (2007) “Estimating evapotranspiration using artificial neural network and minimum climatological data”. *J Irrig Drain Eng* 133(2):83–89

6	Annexes	44
6.1	Resultats per estació i mitjanes globals dels models neuronals.....	44
6.2	Resultats per estació i mitjanes globals dels models empírics sense calibrar	45
6.3	Resultats per estació i mitjanes globals dels models empírics calibrats.....	46
6.4	Indicadors desglossats per any de test	47
6.4.1	RRMSE	47
6.4.2	AARE.....	49
6.4.3	MAE	51
6.5	Selecció d'arquitectura òptima segons el criteri de test i validació	53
6.6	Programes implementats amb Matlab	55
6.6.1	Depuradades	55
6.6.2	Mileni	56
6.6.3	Ordena2	56
6.6.4	Combinacions3.....	56
6.6.5	Final.....	57
6.6.6	Validació4.....	57
6.6.7	Inout5.....	57
6.6.8	Conjunt.....	58
6.6.9	Prova1	58
6.6.10	Hgp2	61
6.6.11	Estàndard	63
6.6.12	Arq.....	63
6.6.13	Anydetest	63
6.6.14	Càlcul de PM-56	63
6.7	Instrumentes de mesura a les estacions del SIAR.....	65
6.7.1	Anemoveleta	65
6.7.2	Pluviòmetre.....	66
6.7.3	Datalogger	67
6.7.4	Termohigròmetre.....	68
6.7.5	Piranòmetre	69

6 Annexes

6.1 Resultats per estació i mitjanes globals dels models neuronals

A continuació es presenten les diferents taules amb diferents indicadors per estació, per cada model neuronal. La mitjana 1 inclou totes les estacions, i la mitjana 2 inclou totes les estacions menys l'estació 3.

Estacions	Criteri de Validació				Criteri de Test			
	MSE	MAE	R ²	AARE	MSE	MAE	R ²	AARE
1	0.2858	0.2242	0.9687	0.1468	0.2810	0.2201	0.9698	0.1442
2	0.3596	0.2873	0.9574	0.1657	0.3191	0.2509	0.9620	0.1465
3	2.9160	2.2338	0.0521	0.5619	2.6589	1.9453	0.0583	0.4864
4	0.4864	0.3753	0.9162	0.1800	0.4787	0.3700	0.9188	0.1790
5	0.3665	0.2705	0.9505	0.1591	0.3569	0.2634	0.9530	0.1586
6	0.3618	0.2940	0.9651	0.1645	0.3139	0.2508	0.9699	0.1446
7	0.3788	0.2891	0.9611	0.1334	0.3749	0.2842	0.9618	0.1310
8	0.3937	0.3134	0.9580	0.1520	0.3652	0.2829	0.9618	0.1394
9	0.3214	0.2460	0.9683	0.1235	0.3176	0.2423	0.9691	0.1217
10	0.3643	0.2774	0.9557	0.1531	0.3592	0.2739	0.9570	0.1524
11	0.2448	0.1858	0.9754	0.1218	0.2396	0.1797	0.9763	0.1188
12	0.3475	0.2802	0.9645	0.1588	0.3230	0.2529	0.9676	0.1465
Mitjana1	0.5689	0.4397	0.8828	0.1850	0.5323	0.4014	0.8855	0.1724
Mitjana2	0.3555	0.2767	0.9583	0.1508	0.3390	0.2610	0.9606	0.1439

Taula 9: Indicadors per estació del model Ann Rs

Estacions	Criteri de Validació				Criteri de Test			
	MSE	MAE	R ²	AARE	MSE	MAE	R ²	AARE
1	0.4368	0.3166	0.9269	0.1558	0.4266	0.3099	0.9305	0.1540
2	0.4666	0.3350	0.9167	0.1629	0.4455	0.3190	0.9238	0.1572
3	2.4210	1.8437	0.1882	0.5269	2.4207	1.8431	0.1961	0.5251
4	0.5937	0.4392	0.8751	0.1824	0.5832	0.4303	0.8795	0.1778
5	0.5245	0.3738	0.8987	0.1802	0.5126	0.3651	0.9032	0.1769
6	0.4552	0.3296	0.9368	0.1561	0.4358	0.3160	0.9411	0.1467
7	0.5599	0.4160	0.9153	0.1794	0.5411	0.3970	0.9205	0.1660
8	0.5591	0.4131	0.9170	0.1821	0.4991	0.3655	0.9285	0.1566
9	0.5281	0.3828	0.9146	0.1644	0.5168	0.3758	0.9181	0.1610
10	0.4915	0.3566	0.9195	0.1693	0.4828	0.3495	0.9222	0.1647
11	0.3710	0.2561	0.9433	0.1311	0.3633	0.2511	0.9458	0.1286
12	0.4339	0.3045	0.9412	0.1433	0.4258	0.3009	0.9434	0.1434
Mitjana1	0.6534	0.4806	0.8578	0.1945	0.6378	0.4686	0.8627	0.1882
Mitjana2	0.4928	0.3567	0.9186	0.1643	0.4757	0.3436	0.9233	0.1575

Taula 10: Indicadors per estació del model Ann Ra

Estacions	Criteri de Validació				Criteri de Test			
	MSE	MAE	R ²	AARE	MSE	MAE	R ²	AARE
1	0.3710	0.2596	0.9474	0.1126	0.3637	0.2540	0.9494	0.1109
2	0.4091	0.2843	0.9357	0.1247	0.3916	0.2707	0.9412	0.1161
3	2.5306	1.9525	0.5773	0.4988	2.3591	1.7918	0.2021	0.5137
4	0.4092	0.2935	0.9407	0.1044	0.3971	0.2853	0.9441	0.1030
5	0.3987	0.2823	0.9414	0.1222	0.3894	0.2770	0.9441	0.1196
6	0.3940	0.2782	0.9518	0.1173	0.3732	0.2622	0.9565	0.1056
7	0.4323	0.3063	0.9493	0.1090	0.4233	0.3004	0.9514	0.1073
8	0.4691	0.3329	0.9397	0.1301	0.4172	0.2952	0.9501	0.1113
9	0.4053	0.2852	0.9503	0.1080	0.3881	0.2769	0.9538	0.1013
10	0.3887	0.2756	0.9496	0.1125	0.3791	0.2700	0.9521	0.1102
11	0.3451	0.2366	0.9516	0.1102	0.3300	0.2237	0.9552	0.1052
12	0.3857	0.2684	0.9535	0.1186	0.3801	0.2642	0.9549	0.1183
Mitjana1	0.5782	0.4213	0.9157	0.1474	0.5493	0.3976	0.8879	0.1435
Mitjana2	0.4007	0.2821	0.9464	0.1154	0.3848	0.2709	0.9503	0.1099

Taula 11: Indicadors per estació del model Ann Hr

6.2 Resultats per estació i mitjanes globals dels models empírics sense calibrar

Estació	MSE			RRMSE			MAE			R^2			AARE		
	HG_{Rs}	HG_{Ra}	HG_{Hr}	HG_{Rs}	HG_{Ra}	HG_{Hr}	HG_{Rs}	HG_{Ra}	HG_{Hr}	HG_{Rs}	HG_{Ra}	HG_{Hr}	HG_{Rs}	HG_{Ra}	HG_{Hr}
1	0.433	0.717	0.311	0.249	0.321	0.212	0.566	0.705	0.427	0.957	0.901	0.932	0.302	0.399	0.242
2	0.349	0.696	0.311	0.213	0.301	0.201	0.501	0.682	0.399	0.943	0.901	0.923	0.246	0.343	0.200
3	0.343	0.579	0.490	0.178	0.231	0.213	0.510	0.555	0.531	0.957	0.883	0.927	0.224	0.215	0.176
4	0.471	1.050	0.835	0.207	0.309	0.276	0.583	0.796	0.732	0.899	0.784	0.868	0.231	0.259	0.224
5	0.402	0.637	0.318	0.227	0.285	0.201	0.534	0.644	0.428	0.942	0.851	0.906	0.245	0.330	0.217
6	0.325	0.587	0.284	0.193	0.260	0.181	0.484	0.639	0.405	0.959	0.920	0.942	0.241	0.336	0.203
7	0.223	0.554	0.280	0.143	0.225	0.160	0.378	0.589	0.386	0.953	0.895	0.926	0.164	0.244	0.144
8	0.211	0.456	0.232	0.143	0.211	0.151	0.374	0.542	0.356	0.952	0.910	0.934	0.176	0.251	0.148
9	0.230	0.522	0.240	0.151	0.228	0.155	0.406	0.582	0.365	0.958	0.888	0.928	0.189	0.280	0.163
10	0.286	0.937	0.299	0.179	0.324	0.183	0.451	0.822	0.413	0.944	0.894	0.925	0.222	0.387	0.202
11	0.509	1.066	0.716	0.289	0.418	0.343	0.576	0.903	0.707	0.970	0.920	0.934	0.245	0.523	0.394
12	0.279	0.518	0.254	0.177	0.241	0.169	0.452	0.599	0.379	0.952	0.919	0.938	0.247	0.340	0.214
Mitjana	0.338	0.693	0.381	0.196	0.280	0.204	0.485	0.672	0.461	0.949	0.889	0.924	0.228	0.326	0.211

Taula 12: Indicadors globals per estació dels models empírics sense calibrar

6.3 Resultats per estació i mitjanes globals dels models empírics calibrats

Estació	MSE			RRMSE			MAE			R ²			AARE		
	HG _{Rs}	HG _{Ra}	HG _{Hr}	HG _{Rs}	HG _{Ra}	HG _{Hr}	HG _{Rs}	HG _{Ra}	HG _{Hr}	HG _{Rs}	HG _{Ra}	HG _{Hr}	HG _{Rs}	HG _{Ra}	HG _{Hr}
1	0.191	0.280	0.195	0.166	0.201	0.168	0.372	0.415	0.337	0.957	0.901	0.932	0.233	0.227	0.167
2	0.248	0.263	0.202	0.180	0.185	0.162	0.418	0.386	0.332	0.943	0.901	0.923	0.218	0.194	0.151
3	0.277	0.469	0.298	0.160	0.208	0.166	0.458	0.516	0.402	0.957	0.883	0.927	0.210	0.236	0.173
4	0.791	0.826	0.422	0.269	0.274	0.196	0.769	0.746	0.509	0.899	0.784	0.868	0.282	0.293	0.199
5	0.629	0.415	0.256	0.283	0.230	0.181	0.670	0.491	0.376	0.942	0.851	0.906	0.287	0.253	0.182
6	0.147	0.304	0.204	0.130	0.187	0.153	0.317	0.425	0.340	0.959	0.920	0.942	0.185	0.201	0.149
7	0.362	0.392	0.284	0.182	0.190	0.161	0.495	0.472	0.389	0.953	0.895	0.926	0.195	0.195	0.146
8	0.339	0.319	0.231	0.182	0.177	0.150	0.486	0.428	0.356	0.952	0.910	0.934	0.208	0.192	0.146
9	0.235	0.370	0.245	0.153	0.192	0.156	0.412	0.462	0.372	0.958	0.888	0.928	0.191	0.213	0.155
10	0.483	0.320	0.226	0.233	0.190	0.159	0.591	0.429	0.345	0.944	0.894	0.925	0.265	0.222	0.167
11	0.908	0.248	0.200	0.386	0.202	0.181	0.758	0.391	0.337	0.970	0.920	0.934	0.298	0.216	0.166
12	0.164	0.330	0.238	0.136	0.193	0.163	0.329	0.451	0.379	0.952	0.919	0.938	0.203	0.221	0.174
Mitjana	0.398	0.378	0.250	0.205	0.202	0.166	0.506	0.468	0.373	0.949	0.889	0.924	0.231	0.222	0.165

Taula 13: Indicadors globals per estació dels models empírics calibrats

6.4 Indicadors desglossats per any de test

6.4.1 RRMSE

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.086	0.080	0.081	0.088	0.083	0.066	0.084	0.070	0.087	0.086	0.085	0.066	0.053	-
2	0.050	0.092	0.105	0.081	0.114	0.084	0.086	0.086	0.123	0.109	0.150	0.101	0.099	-
3	0.103	7.844	-	-	-	-	-	-	-	-	-	-	-	-
4	0.250	0.205	0.210	0.229	0.226	0.253	0.172	0.190	0.223	0.215	0.366	0.352	0.184	-
5	0.158	0.161	0.145	0.121	0.126	0.099	0.101	0.157	0.167	0.100	0.109	0.125	0.094	-
6	0.119	0.111	0.102	0.105	0.086	0.111	0.079	0.118	0.076	0.088	0.116	0.094	0.101	0.079
7	0.185	0.124	0.124	0.170	0.140	0.166	0.091	0.146	0.133	0.125	0.146	0.130	0.159	0.138
8	0.219	0.180	0.146	0.126	0.116	0.108	0.095	0.136	0.112	0.158	0.118	0.144	0.123	0.107
9	0.098	0.086	0.117	0.097	0.095	0.120	0.090	0.088	0.095	0.123	0.121	0.088	0.104	0.079
10	0.122	0.121	0.090	0.153	0.154	0.117	0.091	0.140	0.119	0.130	0.214	0.129	0.108	0.110
11	0.071	0.055	0.063	0.059	0.054	0.046	0.046	0.043	0.089	-	-	-	-	-
12	0.074	0.119	0.133	0.102	0.123	0.114	0.106	0.083	0.075	0.075	0.118	0.113	0.137	0.063

Taula 14: RRMSE per any de test del model Ann Rs amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.306	0.107	0.108	0.114	0.104	0.096	0.101	0.096	0.109	0.116	0.112	0.087	0.132	
2	0.175	0.104	0.114	0.105	0.119	0.102	0.095	0.099	0.125	0.116	0.157	0.111	0.229	
3	0.346	0.789												
4	0.274	0.135	0.134	0.141	0.138	0.151	0.117	0.136	0.141	0.135	0.447	0.190	0.110	
5	0.346	0.140	0.137	0.130	0.122	0.119	0.111	0.148	0.145	0.117	0.116	0.113	0.095	
6	0.103	0.111	0.105	0.109	0.105	0.114	0.099	0.112	0.095	0.109	0.117	0.108	0.112	0.086
7	0.114	0.107	0.108	0.127	0.120	0.122	0.095	0.113	0.115	0.113	0.115	0.113	0.122	0.099
8	0.123	0.129	0.118	0.114	0.115	0.106	0.101	0.109	0.104	0.137	0.109	0.120	0.111	0.091
9	0.089	0.096	0.112	0.105	0.105	0.112	0.100	0.092	0.098	0.117	0.112	0.086	0.094	0.077
10	0.103	0.122	0.098	0.133	0.136	0.116	0.108	0.119	0.113	0.126	0.160	0.126	0.113	0.097
11	0.169	0.097	0.102	0.098	0.095	0.088	0.086	0.078	0.110					
12	0.089	0.117	0.123	0.111	0.122	0.114	0.110	0.086	0.093	0.098	0.113	0.116	0.129	0.072

Taula 15: RRMSE per any de test del model Ann Rs amb el criteri de test

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.040	0.210	0.199	0.172	0.188	0.181	0.166	0.152	0.177	0.215	0.195	0.192	0.130	-
2	0.068	0.170	0.157	0.164	0.159	0.213	0.163	0.189	0.222	0.216	0.351	0.224	0.130	-
3	0.092	6.501	-	-	-	-	-	-	-	-	-	-	-	-
4	0.243	0.310	0.343	0.345	0.417	0.402	0.289	0.265	0.320	0.312	0.161	0.433	0.369	-
5	0.106	0.258	0.275	0.243	0.317	0.245	0.267	0.272	0.312	0.221	0.212	0.279	0.299	-
6	0.237	0.182	0.243	0.236	0.165	0.183	0.189	0.150	0.146	0.191	0.177	0.175	0.151	0.260
7	0.411	0.311	0.315	0.343	0.258	0.324	0.258	0.268	0.242	0.284	0.292	0.229	0.286	0.299
8	0.388	0.259	0.292	0.249	0.222	0.228	0.229	0.207	0.197	0.309	0.229	0.199	0.207	0.334
9	0.271	0.239	0.286	0.266	0.221	0.279	0.293	0.281	0.236	0.269	0.258	0.265	0.322	0.271
10	0.280	0.211	0.249	0.275	0.249	0.214	0.214	0.218	0.229	0.230	0.265	0.170	0.216	0.256
11	0.105	0.129	0.113	0.140	0.122	0.112	0.167	0.129	0.156	-	-	-	-	-
12	0.153	0.164	0.174	0.151	0.193	0.178	0.201	0.173	0.195	0.219	0.164	0.162	0.228	0.167

Taula 16: RRMSE per any de test del model Ann Ra amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.193	0.174	0.168	0.158	0.153	0.158	0.141	0.140	0.150	0.184	0.162	0.145	0.196	
2	0.206	0.141	0.138	0.152	0.136	0.161	0.127	0.144	0.170	0.161	0.246	0.165	0.256	
3	0.315	0.611												
4	0.260	0.165	0.171	0.172	0.186	0.190	0.151	0.160	0.168	0.163	0.294	0.209	0.156	
5	0.281	0.177	0.182	0.178	0.187	0.184	0.176	0.191	0.196	0.173	0.161	0.166	0.165	
6	0.141	0.140	0.155	0.156	0.143	0.146	0.153	0.128	0.132	0.157	0.140	0.146	0.134	0.154
7	0.170	0.166	0.173	0.180	0.160	0.168	0.159	0.150	0.152	0.171	0.162	0.147	0.162	0.145
8	0.155	0.152	0.165	0.158	0.157	0.152	0.154	0.135	0.140	0.191	0.145	0.138	0.144	0.156
9	0.150	0.156	0.172	0.172	0.160	0.169	0.177	0.160	0.149	0.171	0.163	0.147	0.164	0.141
10	0.155	0.163	0.162	0.178	0.169	0.159	0.166	0.146	0.155	0.166	0.178	0.141	0.162	0.148
11	0.187	0.149	0.132	0.148	0.143	0.137	0.165	0.132	0.144					
12	0.128	0.132	0.138	0.131	0.148	0.141	0.148	0.124	0.149	0.164	0.129	0.133	0.165	0.114

Taula 17: RRMSE per any de test del model Ann Ra amb el criteri de test

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.019	0.188	0.125	0.116	0.136	0.127	0.139	0.111	0.126	0.168	0.127	0.151	0.039	-
2	0.034	0.138	0.101	0.113	0.106	0.177	0.145	0.138	0.145	0.179	0.317	0.178	0.080	-
3	0.040	6.179	-	-	-	-	-	-	-	-	-	-	-	-
4	0.086	0.142	0.170	0.147	0.184	0.202	0.149	0.094	0.151	0.191	0.064	0.148	0.204	-
5	0.046	0.179	0.165	0.114	0.171	0.134	0.137	0.149	0.198	0.160	0.097	0.174	0.172	-
6	0.185	0.141	0.161	0.159	0.108	0.142	0.137	0.114	0.111	0.155	0.112	0.124	0.133	0.192
7	0.265	0.171	0.216	0.195	0.168	0.200	0.148	0.177	0.153	0.173	0.169	0.124	0.184	0.185
8	0.289	0.187	0.193	0.155	0.140	0.155	0.150	0.138	0.119	0.358	0.155	0.129	0.150	0.148
9	0.233	0.130	0.168	0.121	0.106	0.144	0.161	0.148	0.119	0.147	0.152	0.143	0.191	0.180
10	0.165	0.114	0.186	0.134	0.125	0.130	0.119	0.140	0.143	0.144	0.251	0.088	0.128	0.150
11	0.105	0.099	0.103	0.098	0.098	0.090	0.146	0.121	0.121	-	-	-	-	-
12	0.134	0.130	0.141	0.099	0.131	0.140	0.156	0.163	0.152	0.170	0.129	0.119	0.215	0.142

Taula 18: RRMSE per any de test del model Ann Hr amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.144	0.164	0.133	0.131	0.133	0.133	0.130	0.121	0.132	0.163	0.137	0.133	0.113	
2	0.143	0.127	0.111	0.124	0.114	0.148	0.123	0.126	0.135	0.148	0.228	0.148	0.205	
3	0.214	0.700												
4	0.161	0.113	0.121	0.113	0.125	0.135	0.109	0.096	0.116	0.128	0.187	0.123	0.116	
5	0.186	0.148	0.146	0.125	0.142	0.138	0.130	0.144	0.158	0.148	0.109	0.133	0.129	
6	0.128	0.125	0.131	0.135	0.117	0.129	0.131	0.110	0.115	0.145	0.115	0.123	0.129	0.134
7	0.136	0.126	0.142	0.136	0.132	0.134	0.121	0.124	0.123	0.133	0.124	0.110	0.131	0.115
8	0.141	0.132	0.135	0.127	0.126	0.126	0.127	0.110	0.108	0.206	0.125	0.113	0.123	0.107
9	0.137	0.118	0.134	0.117	0.112	0.123	0.134	0.119	0.109	0.128	0.126	0.110	0.127	0.117
10	0.120	0.118	0.141	0.125	0.122	0.122	0.124	0.119	0.124	0.133	0.173	0.104	0.123	0.113
11	0.205	0.131	0.130	0.126	0.128	0.123	0.154	0.130	0.128					
12	0.120	0.122	0.127	0.110	0.126	0.127	0.133	0.120	0.133	0.147	0.118	0.119	0.162	0.108

Taula 19: RRMSE per any de test del model Ann Hr amb el criteri de test

6.4.2 AARE

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.276	0.149	0.130	0.132	0.138	0.132	0.154	0.135	0.142	0.174	0.182	0.126	0.128	
2	0.192	0.113	0.131	0.153	0.145	0.134	0.158	0.149	0.193	0.161	0.246	0.193	0.347	
3	0.462	0.573												
4	0.251	0.158	0.145	0.169	0.154	0.169	0.146	0.169	0.162	0.155	0.495	0.319	0.112	
5	0.408	0.153	0.145	0.150	0.143	0.153	0.176	0.155	0.163	0.165	0.163	0.168	0.113	
6	0.150	0.119	0.118	0.141	0.155	0.154	0.152	0.181	0.200	0.150	0.199	0.225	0.204	0.150
7	0.127	0.128	0.121	0.129	0.152	0.139	0.119	0.143	0.134	0.123	0.144	0.150	0.145	0.105
8	0.149	0.149	0.137	0.141	0.141	0.145	0.138	0.180	0.173	0.171	0.156	0.166	0.169	0.102
9	0.115	0.117	0.117	0.123	0.124	0.127	0.117	0.129	0.130	0.139	0.142	0.099	0.154	0.089
10	0.122	0.169	0.126	0.131	0.144	0.137	0.137	0.169	0.149	0.153	0.217	0.206	0.165	0.097
11	0.189	0.139	0.112	0.121	0.121	0.114	0.107	0.116	0.118					
12	0.170	0.133	0.136	0.131	0.143	0.141	0.154	0.144	0.155	0.136	0.150	0.244	0.276	0.106

Taula 20: AARE per any de test del model Ann Rs amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.276	0.139	0.130	0.131	0.135	0.130	0.151	0.135	0.142	0.170	0.180	0.126	0.117	
2	0.136	0.111	0.131	0.128	0.147	0.124	0.132	0.133	0.159	0.157	0.206	0.162	0.245	
3	0.359	0.501												
4	0.244	0.158	0.143	0.171	0.154	0.174	0.146	0.165	0.156	0.154	0.487	0.319	0.110	
5	0.372	0.156	0.151	0.150	0.137	0.158	0.157	0.154	0.163	0.165	0.163	0.180	0.111	
6	0.150	0.132	0.118	0.141	0.128	0.154	0.129	0.166	0.140	0.140	0.164	0.160	0.185	0.116
7	0.126	0.129	0.121	0.126	0.150	0.136	0.119	0.137	0.134	0.118	0.146	0.138	0.145	0.101
8	0.149	0.152	0.132	0.122	0.142	0.126	0.125	0.151	0.136	0.164	0.139	0.160	0.149	0.097
9	0.111	0.117	0.119	0.119	0.123	0.128	0.109	0.129	0.130	0.136	0.140	0.099	0.151	0.087
10	0.126	0.163	0.127	0.131	0.148	0.132	0.137	0.169	0.155	0.147	0.217	0.206	0.165	0.091
11	0.174	0.139	0.114	0.120	0.110	0.111	0.104	0.116	0.115					
12	0.118	0.133	0.126	0.131	0.151	0.140	0.138	0.125	0.129	0.122	0.150	0.224	0.249	0.090

Taula 21: AARE per any de test del model Ann Rs amb el criteri de test

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.195	0.162	0.151	0.147	0.146	0.166	0.144	0.128	0.156	0.183	0.158	0.157	0.176	
2	0.204	0.130	0.130	0.154	0.134	0.169	0.114	0.149	0.162	0.176	0.237	0.196	0.279	
3	0.309	0.551												
4	0.202	0.193	0.152	0.169	0.182	0.204	0.156	0.162	0.151	0.157	0.220	0.314	0.132	
5	0.299	0.154	0.188	0.185	0.174	0.208	0.203	0.163	0.192	0.173	0.158	0.174	0.160	
6	0.156	0.139	0.159	0.167	0.137	0.148	0.162	0.138	0.160	0.196	0.158	0.159	0.151	0.152
7	0.172	0.180	0.193	0.184	0.208	0.173	0.180	0.157	0.173	0.168	0.192	0.184	0.171	0.167
8	0.172	0.189	0.184	0.166	0.172	0.175	0.189	0.172	0.191	0.247	0.160	0.182	0.178	0.164
9	0.153	0.167	0.177	0.158	0.166	0.162	0.196	0.193	0.145	0.147	0.162	0.148	0.189	0.141
10	0.149	0.175	0.149	0.171	0.180	0.150	0.180	0.159	0.168	0.178	0.215	0.156	0.190	0.135
11	0.144	0.128	0.120	0.132	0.134	0.134	0.146	0.113	0.135					
12	0.122	0.128	0.124	0.134	0.148	0.140	0.139	0.116	0.139	0.144	0.132	0.179	0.237	0.103

Taula 22: AARE per any de test del model Ann Ra amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.166	0.164	0.164	0.147	0.146	0.159	0.146	0.125	0.150	0.176	0.158	0.148	0.172	
2	0.164	0.121	0.124	0.142	0.144	0.161	0.116	0.143	0.177	0.158	0.236	0.175	0.278	
3	0.291	0.551												
4	0.210	0.163	0.152	0.165	0.180	0.198	0.153	0.159	0.152	0.157	0.200	0.313	0.135	
5	0.243	0.154	0.186	0.184	0.174	0.213	0.181	0.164	0.189	0.173	0.158	0.166	0.160	
6	0.156	0.139	0.157	0.167	0.137	0.145	0.147	0.119	0.131	0.174	0.144	0.150	0.141	0.146
7	0.161	0.176	0.169	0.184	0.178	0.163	0.175	0.150	0.152	0.165	0.180	0.155	0.163	0.141
8	0.164	0.152	0.159	0.151	0.160	0.150	0.164	0.138	0.156	0.203	0.163	0.138	0.146	0.146
9	0.153	0.160	0.166	0.158	0.162	0.158	0.194	0.174	0.161	0.147	0.156	0.148	0.181	0.136
10	0.153	0.169	0.154	0.171	0.171	0.150	0.180	0.159	0.156	0.174	0.203	0.156	0.167	0.131
11	0.144	0.123	0.115	0.132	0.121	0.132	0.146	0.126	0.129					
12	0.124	0.128	0.130	0.130	0.148	0.137	0.139	0.113	0.145	0.140	0.127	0.182	0.239	0.106

Taula 23: AARE per any de test del model Ann Ra amb el criteri de test

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.124	0.122	0.102	0.106	0.118	0.116	0.114	0.101	0.112	0.131	0.106	0.107	0.110	
2	0.154	0.098	0.091	0.099	0.090	0.118	0.116	0.109	0.129	0.118	0.232	0.151	0.204	
3	0.236	0.528												
4	0.125	0.096	0.103	0.097	0.107	0.124	0.096	0.085	0.104	0.105	0.123	0.123	0.096	
5	0.195	0.116	0.123	0.119	0.118	0.126	0.127	0.117	0.133	0.128	0.105	0.129	0.107	
6	0.102	0.103	0.108	0.112	0.094	0.113	0.109	0.106	0.098	0.126	0.149	0.134	0.161	0.120
7	0.119	0.115	0.108	0.110	0.123	0.109	0.108	0.119	0.102	0.111	0.105	0.094	0.108	0.099
8	0.118	0.108	0.118	0.109	0.133	0.127	0.118	0.102	0.131	0.213	0.163	0.119	0.140	0.110
9	0.110	0.098	0.106	0.098	0.091	0.112	0.125	0.121	0.097	0.114	0.119	0.105	0.117	0.101
10	0.110	0.102	0.113	0.109	0.108	0.107	0.108	0.104	0.111	0.123	0.156	0.103	0.116	0.097
11	0.119	0.108	0.103	0.101	0.113	0.114	0.130	0.093	0.114					
12	0.102	0.106	0.101	0.098	0.117	0.110	0.119	0.098	0.110	0.110	0.109	0.153	0.221	0.090

Taula 24: AARE per any de test del model Ann Hr amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.124	0.126	0.105	0.106	0.116	0.115	0.104	0.093	0.112	0.131	0.106	0.107	0.093	
2	0.116	0.102	0.091	0.099	0.090	0.109	0.091	0.094	0.112	0.125	0.191	0.152	0.207	
3	0.191	0.550												
4	0.126	0.096	0.099	0.096	0.110	0.118	0.096	0.085	0.101	0.105	0.131	0.115	0.095	
5	0.166	0.111	0.117	0.112	0.120	0.128	0.121	0.117	0.136	0.128	0.099	0.125	0.107	
6	0.101	0.103	0.103	0.112	0.092	0.107	0.109	0.095	0.098	0.126	0.096	0.103	0.116	0.118
7	0.114	0.112	0.108	0.108	0.117	0.114	0.108	0.107	0.104	0.110	0.105	0.087	0.106	0.101
8	0.118	0.111	0.109	0.100	0.106	0.109	0.111	0.105	0.099	0.197	0.105	0.091	0.103	0.092
9	0.105	0.098	0.106	0.097	0.090	0.103	0.113	0.100	0.090	0.108	0.101	0.093	0.115	0.102
10	0.113	0.100	0.108	0.108	0.108	0.103	0.109	0.104	0.111	0.116	0.155	0.092	0.116	0.096
11	0.107	0.108	0.106	0.101	0.103	0.105	0.117	0.090	0.109					
12	0.098	0.114	0.100	0.098	0.117	0.110	0.109	0.096	0.110	0.121	0.102	0.153	0.220	0.090

Taula 25: AARE per any de test del model Ann Hr amb el criteri de test

6.4.3 MAE

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.251	0.221	0.216	0.217	0.229	0.200	0.237	0.206	0.241	0.251	0.239	0.224	0.176	
2	0.245	0.244	0.252	0.241	0.265	0.243	0.263	0.302	0.356	0.308	0.357	0.315	0.377	
3	0.356	2.442												
4	0.428	0.340	0.345	0.378	0.364	0.401	0.327	0.361	0.374	0.364	0.551	0.472	0.322	
5	0.396	0.289	0.264	0.255	0.261	0.231	0.318	0.274	0.294	0.251	0.245	0.287	0.254	
6	0.280	0.254	0.247	0.255	0.257	0.312	0.264	0.324	0.309	0.250	0.326	0.353	0.341	0.359
7	0.324	0.274	0.269	0.293	0.306	0.314	0.238	0.294	0.272	0.261	0.301	0.296	0.311	0.304
8	0.352	0.330	0.315	0.294	0.274	0.314	0.276	0.334	0.353	0.340	0.314	0.309	0.304	0.288
9	0.253	0.228	0.245	0.238	0.241	0.258	0.228	0.227	0.239	0.270	0.275	0.232	0.279	0.231
10	0.256	0.278	0.234	0.280	0.295	0.261	0.238	0.303	0.267	0.268	0.377	0.306	0.260	0.248
11	0.242	0.181	0.183	0.187	0.182	0.169	0.178	0.166	0.223					
12	0.274	0.277	0.294	0.251	0.266	0.270	0.314	0.263	0.299	0.234	0.277	0.318	0.322	0.254

Taula 26: MAE per any de test del model Ann Rs amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.251	0.218	0.216	0.215	0.225	0.197	0.234	0.206	0.237	0.243	0.233	0.210	0.165	
2	0.172	0.240	0.252	0.222	0.265	0.225	0.240	0.236	0.278	0.256	0.304	0.256	0.265	
3	0.286	2.130												
4	0.411	0.340	0.341	0.371	0.364	0.390	0.327	0.351	0.360	0.361	0.541	0.472	0.319	
5	0.350	0.290	0.264	0.255	0.256	0.239	0.248	0.272	0.291	0.251	0.246	0.278	0.242	
6	0.280	0.261	0.247	0.255	0.232	0.257	0.226	0.287	0.220	0.238	0.277	0.252	0.263	0.227
7	0.322	0.273	0.269	0.288	0.301	0.303	0.238	0.284	0.272	0.253	0.300	0.284	0.311	0.290
8	0.352	0.330	0.285	0.266	0.265	0.253	0.242	0.292	0.264	0.326	0.276	0.287	0.287	0.252
9	0.241	0.228	0.243	0.235	0.237	0.258	0.222	0.227	0.239	0.267	0.272	0.232	0.264	0.222
10	0.259	0.273	0.233	0.279	0.297	0.252	0.238	0.303	0.271	0.258	0.376	0.296	0.260	0.228
11	0.199	0.181	0.186	0.182	0.172	0.166	0.160	0.166	0.221					
12	0.205	0.277	0.281	0.251	0.260	0.257	0.255	0.238	0.223	0.217	0.277	0.261	0.301	0.201

Taula 27: MAE per any de test del model Ann Rs amb el criteri de test

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.171	0.311	0.335	0.299	0.333	0.330	0.297	0.288	0.314	0.357	0.319	0.353	0.256	
2	0.241	0.307	0.287	0.298	0.297	0.390	0.280	0.365	0.342	0.337	0.449	0.362	0.289	
3	0.265	2.019												
4	0.368	0.454	0.438	0.449	0.480	0.497	0.406	0.394	0.422	0.409	0.284	0.507	0.418	
5	0.289	0.358	0.401	0.368	0.400	0.373	0.388	0.383	0.413	0.343	0.321	0.390	0.373	
6	0.371	0.317	0.371	0.366	0.289	0.318	0.319	0.296	0.292	0.375	0.316	0.329	0.302	0.375
7	0.487	0.418	0.412	0.432	0.413	0.421	0.387	0.386	0.378	0.399	0.434	0.414	0.409	0.450
8	0.477	0.414	0.413	0.402	0.376	0.359	0.430	0.407	0.398	0.568	0.360	0.364	0.392	0.457
9	0.410	0.374	0.401	0.370	0.351	0.388	0.413	0.408	0.352	0.356	0.374	0.377	0.436	0.371
10	0.393	0.344	0.341	0.380	0.375	0.344	0.345	0.345	0.360	0.358	0.406	0.299	0.355	0.351
11	0.200	0.243	0.228	0.265	0.249	0.250	0.306	0.251	0.281					
12	0.263	0.295	0.296	0.292	0.321	0.294	0.332	0.304	0.311	0.304	0.286	0.292	0.375	0.274

Taula 28: MAE per any de test del model Ann Ra amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.148	0.317	0.334	0.299	0.333	0.322	0.300	0.282	0.300	0.336	0.319	0.321	0.242	
2	0.184	0.293	0.284	0.290	0.284	0.353	0.284	0.331	0.341	0.325	0.445	0.316	0.283	
3	0.258	2.019												
4	0.368	0.416	0.438	0.442	0.475	0.481	0.393	0.386	0.421	0.406	0.268	0.498	0.425	
5	0.235	0.358	0.389	0.369	0.400	0.373	0.350	0.365	0.399	0.343	0.321	0.371	0.373	
6	0.371	0.317	0.370	0.366	0.289	0.314	0.311	0.276	0.268	0.324	0.297	0.305	0.283	0.358
7	0.470	0.416	0.393	0.432	0.386	0.414	0.382	0.376	0.347	0.389	0.414	0.350	0.401	0.398
8	0.471	0.369	0.390	0.363	0.348	0.341	0.352	0.333	0.330	0.432	0.359	0.321	0.344	0.405
9	0.410	0.361	0.389	0.370	0.345	0.380	0.407	0.387	0.355	0.356	0.364	0.377	0.414	0.362
10	0.392	0.328	0.341	0.380	0.367	0.341	0.345	0.345	0.342	0.356	0.393	0.293	0.334	0.342
11	0.199	0.239	0.226	0.264	0.235	0.232	0.304	0.260	0.268					
12	0.263	0.295	0.290	0.282	0.321	0.292	0.332	0.298	0.307	0.301	0.281	0.290	0.368	0.267

Taula 29: MAE per any de test del model Ann Ra amb el criteri de test

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.109	0.274	0.250	0.250	0.294	0.265	0.292	0.241	0.244	0.288	0.251	0.269	0.182	
2	0.179	0.252	0.225	0.234	0.231	0.330	0.309	0.290	0.292	0.290	0.436	0.288	0.216	
3	0.196	2.148												
4	0.227	0.269	0.324	0.292	0.310	0.345	0.283	0.230	0.285	0.298	0.172	0.326	0.313	
5	0.201	0.303	0.309	0.264	0.300	0.277	0.274	0.284	0.309	0.282	0.231	0.293	0.278	
6	0.324	0.273	0.297	0.291	0.233	0.271	0.262	0.263	0.223	0.277	0.297	0.291	0.306	0.309
7	0.402	0.304	0.312	0.318	0.313	0.326	0.279	0.324	0.261	0.292	0.302	0.254	0.303	0.324
8	0.401	0.322	0.337	0.300	0.301	0.345	0.289	0.273	0.296	0.527	0.345	0.314	0.312	0.309
9	0.367	0.260	0.288	0.251	0.228	0.280	0.288	0.298	0.255	0.288	0.309	0.296	0.317	0.303
10	0.310	0.241	0.273	0.276	0.257	0.275	0.258	0.266	0.275	0.275	0.403	0.223	0.253	0.280
11	0.175	0.216	0.209	0.225	0.218	0.240	0.314	0.233	0.262					
12	0.246	0.271	0.256	0.227	0.266	0.256	0.309	0.299	0.261	0.252	0.260	0.248	0.351	0.247

Taula 30: MAE per any de test del model Ann Hr amb el criteri de validació

Estació	Any de test													
	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.109	0.272	0.249	0.250	0.279	0.264	0.266	0.233	0.244	0.288	0.251	0.269	0.141	
2	0.133	0.250	0.229	0.234	0.231	0.314	0.261	0.263	0.261	0.298	0.401	0.283	0.213	
3	0.166	1.972												
4	0.226	0.269	0.307	0.283	0.315	0.340	0.280	0.230	0.276	0.293	0.173	0.281	0.310	
5	0.165	0.292	0.297	0.249	0.301	0.272	0.270	0.276	0.306	0.286	0.225	0.299	0.278	
6	0.318	0.273	0.286	0.291	0.223	0.269	0.260	0.239	0.223	0.277	0.235	0.243	0.257	0.301
7	0.376	0.302	0.308	0.312	0.301	0.328	0.278	0.302	0.262	0.289	0.302	0.243	0.298	0.324
8	0.401	0.312	0.311	0.284	0.267	0.275	0.275	0.277	0.240	0.450	0.278	0.243	0.269	0.282
9	0.358	0.260	0.288	0.249	0.227	0.271	0.283	0.287	0.247	0.266	0.280	0.279	0.306	0.313
10	0.303	0.237	0.269	0.273	0.257	0.260	0.259	0.266	0.272	0.267	0.390	0.212	0.250	0.272
11	0.165	0.216	0.211	0.225	0.210	0.202	0.280	0.226	0.243					
12	0.239	0.260	0.247	0.227	0.266	0.258	0.284	0.290	0.261	0.261	0.251	0.248	0.351	0.248

Taula 31: : MAE per any de test del model Ann Hr amb el criteri de test

6.5 Selecció d'arquitectura òptima segons el criteri de test i validació

Any de test	Estació											
	1	2	3	4	5	6	7	8	9	10	11	12
1	5	5	2	4	6	4	8	9	8	10	8	4
2	7	5	9	7	8	10	10	9	10	9	9	2
3	7	10	-	4	10	8	8	6	10	7	9	10
4	6	7	-	4	7	7	9	2	5	7	9	6
5	6	5	-	8	9	4	10	6	10	10	8	8
6	8	8	-	7	8	2	8	7	5	10	10	2
7	6	6	-	9	9	9	6	8	7	8	10	3
8	7	6	-	7	8	5	9	8	9	6	10	9
9	9	6	-	3	9	7	10	9	8	8	9	3
10	10	8	-	10	7	8	7	9	9	7	-	7
11	9	6	-	10	10	6	9	6	10	9	-	9
12	8	8	-	10	9	5	7	5	8	10	-	7
13	5	4	-	3	8	6	4	5	8	9	-	8
14	-	-	-	-	-	5	9	8	9	9	-	5
Mitjana	7.15	6.46	5.50	6.62	8.31	6.23	8.08	6.85	8.23	8.46	9.11	6.00

Taula 32: N^o de neurones ocultes per any de test en el model Ann Rs amb el criteri de validació

Any de test	Estació											
	1	2	3	4	5	6	7	8	9	10	11	12
1	6	7	6	3	5	9	8	4	9	9	3	2
2	6	2	10	10	4	4	9	6	2	7	2	3
3	10	9	-	10	8	3	9	8	10	6	3	4
4	10	7	-	9	10	3	4	4	4	3	10	3
5	1	10	-	5	9	4	3	9	3	5	10	5
6	1	7	-	8	3	8	2	3	7	8	7	4
7	7	10	-	1	2	2	10	8	6	7	8	8
8	8	8	-	8	8	1	4	1	7	5	1	1
9	7	9	-	4	7	10	8	4	5	4	9	9
10	1	5	-	2	6	10	1	6	5	7	-	2
11	4	4	-	10	10	6	6	3	6	10	-	7
12	3	3	-	8	4	2	2	8	9	7	-	4
13	4	3	-	3	7	4	10	10	10	5	-	1
14	-	-	-	-	-	7	2	10	5	1	-	10
Mitjana	5.23	6.46	8.00	6.23	6.38	5.08	5.85	5.69	6.38	6.38	5.89	4.08

Taula 33: N^o de neurones ocultes per any de test en el model Ann Rs amb el criteri de test

Any de test	Estació											
	1	2	3	4	5	6	7	8	9	10	11	12
1	5	9	8	5	9	10	7	4	9	10	9	6
2	9	8	4	10	10	4	7	6	7	8	8	7
3	9	3	-	4	7	8	8	9	7	10	9	10
4	10	7	-	8	10	9	10	6	10	10	10	8
5	6	4	-	4	6	5	10	10	9	7	6	5
6	4	5	-	4	8	5	10	9	10	10	8	9
7	5	9	-	4	7	10	10	8	9	6	5	8
8	7	6	-	7	9	10	9	9	8	7	4	10
9	3	8	-	6	10	8	6	9	8	7	9	7
10	7	7	-	6	10	8	6	8	9	10	-	7
11	10	7	-	4	9	5	10	8	9	5	-	8
12	10	10	-	7	10	6	6	7	9	5	-	8
13	7	5	-	4	10	10	10	9	9	7	-	6
14	-	-	-	-	-	6	9	10	9	9	-	9
Mitjana	7.08	6.77	6.00	5.62	8.85	7.54	8.38	7.85	8.69	7.85	7.56	7.62

Taula 34: N^o de neurones ocultes per any de test en el model Ann Ra amb el criteri de validació

Nº Neurones		Estació											
Any de test	1	2	3	4	5	6	7	8	9	10	11	12	
1	5	4	8	8	4	4	1	1	7	8	2	2	
2	7	3	5	5	1	2	2	2	9	9	2	10	
3	4	9	-	9	10	1	10	6	2	8	5	7	
4	7	1	-	2	6	8	4	6	7	5	2	5	
5	3	9	-	5	4	9	7	2	10	2	2	6	
6	8	3	-	6	8	7	8	4	4	4	10	9	
7	9	3	-	1	6	1	8	5	2	10	9	1	
8	9	8	-	10	10	8	6	1	6	10	1	8	
9	2	9	-	9	4	2	5	7	4	7	4	2	
10	9	4	-	6	9	6	4	2	9	1	-	6	
11	1	2	-	7	1	6	1	8	10	2	-	8	
12	7	3	-	6	8	10	7	9	5	6	-	2	
13	6	7	-	6	8	8	3	8	6	9	-	9	
14	-	-	-	-	-	4	10	6	4	8	-	1	
Mitjana	5.92	5.00	6.50	6.15	6.08	5.54	5.08	4.69	6.23	6.23	4.11	5.77	

Taula 35: Nº de neurones ocultes per any de test en el model Ann Ra amb el criteri de test

		Estacions											
Any de test	1	2	3	4	5	6	7	8	9	10	11	12	
1	10	10	8	9	7	10	7	6	10	9	8	6	
2	9	9	5	9	10	10	7	8	9	8	10	9	
3	9	7	-	10	7	4	9	7	8	9	8	9	
4	10	6	-	10	7	9	10	6	10	10	8	10	
5	8	7	-	10	7	10	8	6	7	8	10	10	
6	10	8	-	10	10	9	10	9	9	8	7	8	
7	10	9	-	10	8	10	10	10	10	10	4	10	
8	10	10	-	7	9	9	9	9	7	10	10	8	
9	10	8	-	10	10	10	9	7	10	10	10	10	
10	10	9	-	10	9	9	8	10	8	9	-	10	
11	10	8	-	9	9	6	7	4	7	10	-	8	
12	10	9	-	9	8	7	9	8	6	10	-	8	
13	9	6	-	8	10	10	10	6	8	10	-	9	
14	-	-	-	-	-	8	9	10	6	10	-	10	
Mitjana	9.62	8.15	6.50	9.31	8.54	8.69	8.69	7.38	8.38	9.31	8.33	8.85	

Taula 36: Nº de neurones ocultes per any de test en el model Ann Hr amb el criteri de validació

		Estació											
Any de test	1	2	3	4	5	6	7	8	9	10	11	12	
1	7	9	9	6	3	2	2	7	9	10	1	1	
2	10	8	1	2	7	6	6	5	6	7	6	1	
3	8	2	-	3	5	1	8	6	8	5	3	1	
4	1	8	-	5	8	6	10	9	6	9	10	7	
5	9	5	-	7	10	2	7	1	1	1	5	5	
6	8	5	-	2	2	4	2	9	4	1	7	10	
7	6	2	-	1	2	3	1	10	2	2	4	8	
8	1	8	-	2	9	2	8	1	4	10	6	5	
9	1	3	-	10	1	4	8	4	2	1	9	1	
10	9	9	-	6	4	8	7	9	9	4	-	1	
11	2	6	-	5	5	4	6	3	8	5	-	10	
12	7	10	-	9	2	2	6	3	4	6	-	2	
13	6	10	-	4	1	4	2	10	2	1	-	10	
14	-	-	-	-	-	4	1	8	4	6	-	7	
Mitjana	5.77	6.54	5.00	4.77	4.54	3.69	5.62	5.92	5.00	4.77	5.67	4.77	

Taula 37: Nº de neurones ocultes per any de test en el model Ann Hr amb el criteri de test

6.6 Programes implementats amb Matlab

6.6.1 Depuradades

```
function Z=depuradades(est,v)

% a es el cell est
%v es un vector fila amb el nombre de columna de les variables que volem
%analitzar
% Dades de columnes
% 1-id provincia 2-id Estacio 3-fecha 4-dia 5-mes 6-any 7-any 8-dia(1-365)
9-tmedia 10-tmax 11-tmin 12-H temps 13-H mitja 14-Hmax 15-Hmin 16-Hora
humed 17- Vvent 18-dir vent 19-vel vent max 20- dir vent max 21rad 22-
precip 23- p Pmont 24-ET Mon

k=1;
for i=1:max(size(est))

    for j=1:max(size(v(1,:)))

        b1{i}{j}=find(est{i}(:,v(1,j))~=0);
        est{i}=est{i}(b1{i}{j},:);
        s(k,i)=max(size(est{i}));
    end
end

k=2;
for i=1:max(size(est))
    for j=1:max(size(v(1,:)))
        b2{i}{j}=isnan(est{i}(:,v(1,j)));
        b22{i}{j}=find(b2{i}{j}==0);
        est{i}=est{i}(b22{i}{j},:);
        s(k,i)=max(size(est{i}));
    end
end

k=3;
for i=1:12

m{i}=mean(est{i});
d{i}=std(est{i});

end

for i=1:max(size(est))
    for j=1:max(size(v(1,:)))

        b3{i}{j}=find(est{i}(:,v(1,j))<(m{i}(1,v(1,j))+3*d{i}(1,v(1,j))));
        est{i}=est{i}(b3{i}{j},:);
        s(k,i)=max(size(est{i}));
    end
end

k=4;
for i=1:max(size(est))
```

```

    for j=1:max(size(v(1,:)))

        b4{i}{j}=find(est{i}(:,v(1,j))>(m{i}(1,v(1,j))-3*d{i}(1,v(1,j))));
        est{i}=est{i}(b4{i}{j},:);
        s(k,i)=max(size(est{i}));
    end
end

Z={est,s};

```

6.6.2 Mileni

```

function M=mileni(a)
for i=1:max(size(a))
m0{i}=a{i}(:,6)-2000;
m1{i}=a{i}(:,7)-2000;
M{i}=[a{i}(:,1:5) m0{i}(:,1) m1{i}(:,1) a{i}(:,8:27)];
end
end
% ES EL PRIMER PAS
%Agafa les dades de estacions i les neteja:
% pasa els anys de milenies a unitats Ex: 2005=5

```

6.6.3 Ordena2

```

function M=ordena2(a)
for i=1:12
    for j=min(a{i}(:,6)):max(a{i}(:,6))
        m0{i}{j}=find(a{i}(:,6)==j);
        M{i}{j-min(a{i}(:,6))+1}=a{i}(m0{i}{j},:);
    end
end

%SEGON PAS
%Un pic pasat estacions per mileni, aquest ordenara els anys de cada
%estació , per al següent pas

```

6.6.4 Combinacions3

```

function M=combinacions3(a)
for i=1:max(size(a))
    for j=1:max(size(a{i}))
        M{i}{j}{1}=j;
        if j==1
            M{i}{j}{2}=2:max(size(a{i}));
        elseif j==max(size(a{i}))
            M{i}{j}{2}=1:max(size(a{i}))-1;
        else
            M{i}{j}{2}=[1:j-1 j+1:max(size(a{i}))];
        end
    end
end
end
end

```



```

%TERCER PAS
%Agafa les dades de les estacions ja separades anualment , i prepara
%les combinacions dels anys possibles , sempre deixant un fora "leave
%one out"

```

6.6.5 Final

```

function M=final(a,b)
for i=1:max(size(a))
    for j=1:max(size(b{i}))
        M{i}{j}{1}=a{i}{j};
        M{i}{j}{2}=vertcat(a{i}{b{i}{j}}{2});
    end
end
end
%QUART PAS
% a serà la matriu estacions ja en forma de anys mileni , i dividida cada
% estació en anys
% b serà com s'organitza les dades extretes de "combinacions"

```

6.6.6 Validació4

```

function M=validacio4(a,b) % a= matriu estacion , b percentatge de numeros
per hold out.
for i=1:max(size(a))% Variable per numero de estacions
    for j=1:max(size(a{i})) %Variable per numero de combinacions
        m1{i}{j}=randperm(max(size(a{i}{j}}{2})); % Matriu de 1:(numero de
valors de la combinacio{j})
        m2{i}{j}=round(b*max(size(a{i}{j}}{2})); %Numero que es troba al
30%(b) dels valors totals
        m21{i}{j}=m2{i}{j}+1; %Numero que es troba al
30%(b) dels valros totals +1

        m31{i}{j}=size(a{i}{j}}{2});
        m3{i}{j}=m31{i}{j}(1,1);
        %Numero maxim de valors de la combinacio
        %for p=1:m2{i}{j} %1: n°(30%)
        m4{i}{j}(1:m2{i}{j},:)=a{i}{j}}{2}(1:m2{i}{j},:); %%Agafa els
valors per val%%
        % end
        % for q=m21{i}{j}:m3{i}{j} %n°(30%):n°(max)
        m5{i}{j}(1:(m3{i}{j}-
m2{i}{j}),:)=a{i}{j}}{2}(m21{i}{j}:m3{i}{j},:); %%Agafa els valors per
tr%%
        % end
        M{i}{j}{2}=m4{i}{j};
        M{i}{j}{3}=m5{i}{j};
        M{i}{j}{1}=a{i}{j}}{1};
    end
end
end
%4rt pas

```

6.6.7 Inout5

```

function M=inout5(a,b,c) %b= columnes de inputs % c columna outputs
for i=1:max(size(a))

```

```

for j=1:max(size(a{i}))
    M{i}{j}{3}{1}=a{i}{j}{3}(:,b);    %i    %La tercera celda es la que
conte TRAINING
    M{i}{j}{3}{2}=a{i}{j}{3}(:,c);    %o
    M{i}{j}{2}{1}=a{i}{j}{2}(:,b);    %i    %La segona celda es la que
conte cross validation
    M{i}{j}{2}{2}=a{i}{j}{2}(:,c);    %o
    M{i}{j}{1}{1}=a{i}{j}{1}(:,b);    %i    %LA primera caixa conte l'any
que es deixa fora
    M{i}{j}{1}{2}=a{i}{j}{1}(:,c);    %o

```

end

end

```

%Darrer pas , separa per inputs i outputs
%Resum de la estructura final;
% 1Estacio
% 2Combinacions anuals(1 any sempre defora
% 3Cel.les amb Te Cr Tr
% 4Inputs{1} outputs{2}

```

6.6.8 Conjunt

```

function M=CONJUNT(a,b,c,d) % a matriu amb les dades de estacions
m1=mileni(a);              % b columnes de inputs
m2=ordena2(m1);            % c column outputs
m31=combinacions3(m2);     % d %de cross validation?
m3=final(m2,m31);         % (passa un tant per cent de traing a CV)
m4=validacio4(m3,d);
M=inout5(m4,b,c);
end

```

6.6.9 Proval

```

function p=proval(P,v,n,r,b1,b2,x,fa)
%%enrecordar de calcular Radiacio extraterrestre i implementar-la a
%%estacions(P) en aquest cas , per a entrenar els models que ho necessitin
%%com a input
%aplica xarxes versió 1
% Tmean=9 Tmax=10 Tmin=11 HRm=13 Rs=21 Etpm= 24 Ramal=25 Rabe=26 Et0PM=27
tic

```

```

tt=filtro2(P,[b1,b2]);
%P són les dades
% és el % de cv
%n és el n de neurones max
%r és el n de repeticions max
% b1 és un vector fila amb els inputs
%b2 és la columna de l'output
%%x és 1 si volem una capa oculta o 2 si volem 2 capes ocultes
% funció d'activació escollida.
%fa és la funció d'activació escollida, 1 tansig, 2 logsig

```

```

M=CONJUNT(tt{1},b1,b2,v);

```

```

for j=1:max(size(M))
    k=1;
for i=1:max(size(M{j}))

```

```

tri{j}{i}=M{j}{i}{3}{1}';
tro{j}{i}=M{j}{i}{3}{2}';

ValV.P=M{j}{i}{2}{1}'; %no he de posar la diferenciació de {j}{i}
ValV.T=M{j}{i}{2}{2}'; %per a que en la següent iteració no es
confongui??

testV.P=M{j}{i}{1}{1}'; %idem pregunta que adalt
testV.T=M{j}{i}{1}{2}';

M1{j}{i}={tri{j}{i},tro{j}{i},ValV,testV};

%entrenem les ANNs si escollim una capa oculta s'aplica el programa
entrenatestal (L o T segons fa escollida),
%si escollim dues capes ocultes s'aplica el programa entrenatesta2 (L o T
segons fa escollida)

if x==1
    if fa==1
        %en principi de moment, a 3.12.12 només es considerara lT
w{j}{i}=entrenatestalTalt(M1{j}{i}{1},M1{j}{i}{2},M1{j}{i}{3},M1{j}{i}{4},r
,n);
        else
w{j}{i}=entrenatestalLalt(M1{j}{i}{1},M1{j}{i}{2},M1{j}{i}{3},M1{j}{i}{4},r
,n);
        end
    else
        if fa==1
w{j}{i}=entrenatesta2Talt(M1{j}{i}{1},M1{j}{i}{2},M1{j}{i}{3},M1{j}{i}{4},r
,n);
        else
w{j}{i}=entrenatesta2Lalt(M1{j}{i}{1},M1{j}{i}{2},M1{j}{i}{3},M1{j}{i}{4},r
,n);
        end
    end

    ind{j}(i,:)=w{j}{i}{1};
    Tt{j}{i}=w{j}{i}{2}{1}';
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%

%anàlisis arq opt
%cell amb matrius d'errors optims per arquitectura
%primera fila train, segona val i tercera test
% a més calculem l'error de test alternatiu emprant el optim de test
%i l'arquitectura corresponents col 1: test, col2:cval

ar1{j}{i}=[w{j}{i}{3}{2}(2,:);w{j}{i}{3}{6}(2,:)];
mar1{j}{i}=mean(ar1{j}{i});

```

```

ar{j}{i}=[w{j}{i}{3}{4}(2,:);w{j}{i}{3}{2}(2,:);w{j}{i}{3}{6}(2,:);mar1{j}{i}];

%criteri de test
for jj=1:max(size(ar{j}{i}(1,:)))
    if ar{j}{i}(3,jj)==min(ar{j}{i}(3,:))
        MM{j}(i,:)=[jj,w{j}{i}{3}{1}(1,2)];
    else
        end
end

aa2{j}{i}=sim(w{j}{i}{5}{w{j}{i}{3}{1}(1,1)}{MM{j}(i,1)}{w{j}{i}{6}{w{j}{i}{3}{1}(1,1)}{MM{j}(i,1)}{2},M1{j}{i}{4}.P);
Tt2{j}{i}=[aa2{j}{i}',M1{j}{i}{4}.T'];

%montem la matriu de simulacions global
%primera columna sim i segona test

for l1=1:max(size(Tt{j}{i}(:,1)))
    Tsg{j}(k,:)=Tt{j}{i}(l1,:);
    Tsg2{j}(k,:)=Tt2{j}{i}(l1,:);
    k=k+1;
end

%mse parcial per emisor
mm{j}(i,1)=mse(Tt{j}{i}(:,1)-Tt{j}{i}(:,2));
mmT{j}(i,1)=mse(Tt2{j}{i}(:,1)-Tt2{j}{i}(:,2));
%mrse relatiu per emisor
mm{j}(i,2)=(mse(Tt{j}{i}(:,1)-Tt{j}{i}(:,2)))^0.5/mean(Tt{j}{i}(:,2));
mmT{j}(i,2)=(mse(Tt2{j}{i}(:,1)-Tt2{j}{i}(:,2))-
Tt2{j}{i}(:,2)))^0.5/mean(Tt2{j}{i}(:,2));
%mae parcial per emisor
mm{j}(i,3)=mae(Tt{j}{i}(:,1)-Tt{j}{i}(:,2));
mmT{j}(i,3)=mae(Tt2{j}{i}(:,1)-Tt2{j}{i}(:,2));
%nash
mm{j}(i,4)=1-((sum((Tt{j}{i}(:,2)-
Tt{j}{i}(:,1)).^2))/sum((Tt{j}{i}(:,2)-
repmat(mean(Tt{j}{i}(:,2)),size(Tt{j}{i}(:,2))))).^2));
mmT{j}(i,4)=1-((sum((Tt2{j}{i}(:,2)-
Tt2{j}{i}(:,1)).^2))/sum((Tt2{j}{i}(:,2)-
repmat(mean(Tt2{j}{i}(:,2)),size(Tt2{j}{i}(:,2))))).^2));
%r2
rr{j}{i}=corrcoef(Tt{j}{i}(:,1),Tt{j}{i}(:,2));
rrT{j}{i}=corrcoef(Tt2{j}{i}(:,1),Tt2{j}{i}(:,2));
%no té sentit perquè el tamany de test és 1 punt, per tant rr no és
%matriu i sempre és igual a 1
if max(size(Tt{j}{i}(:,1)))==1
    mm{j}(i,5)=rr{j}{i};
    mmT{j}(i,5)=rrT{j}{i};
else
    mm{j}(i,5)=rr{j}{i}(2,1).^2;
    mmT{j}(i,5)=rrT{j}{i}(2,1).^2;
end
%aare
mm{j}(i,6)=mean(abs(Tt{j}{i}(:,1)-Tt{j}{i}(:,2))./Tt{j}{i}(:,2));
mmT{j}(i,6)=mean(abs(Tt2{j}{i}(:,1)-Tt2{j}{i}(:,2))./Tt2{j}{i}(:,2));
%average ratio Ra segons paper
mm{j}(i,7)=mean(abs(Tt{j}{i}(:,1)))/mean(abs(Tt{j}{i}(:,2)));

```

end

```
%idem referit a tots els emisor globalment
mmG(j,1)=mse(Tsg{j}(:,1)-Tsg{j}(:,2))^0.5;
mmG(j,2)=(mse(Tsg{j}(:,1)-Tsg{j}(:,2)))^0.5/mean(Tsg{j}(:,2));
mmG(j,3)=mae(Tsg{j}(:,1)-Tsg{j}(:,2));
mmG(j,3)=mae(Tsg{j}(:,1)-Tsg{j}(:,2));
mmG(j,4)=1-((sum((Tsg{j}(:,2)-Tsg{j}(:,1)).^2))/sum((Tsg{j}(:,2)-
repmat(mean(Tsg{j}(:,2)),size(Tsg{j}(:,2))))).^2));
rrG{j}=corrcoef(Tsg{j}(:,1),Tsg{j}(:,2));
mmG(j,5)=rrG{j}(2,1).^2;
mmG(j,6)=mean(abs(Tsg{j}(:,1)-Tsg{j}(:,2))./Tsg{j}(:,2));
mmG(j,7)=mean(abs(Tsg{j}(:,1)))/mean(abs(Tsg{j}(:,2)));

mmG2(j,1)=mse(Tsg2{j}(:,1)-Tsg2{j}(:,2))^0.5;
mmG2(j,2)=(mse(Tsg2{j}(:,1)-Tsg2{j}(:,2)))^0.5/mean(Tsg2{j}(:,2));
mmG2(j,3)=mae(Tsg2{j}(:,1)-Tsg2{j}(:,2));
mmG2(j,4)=1-((sum((Tsg2{j}(:,2)-Tsg2{j}(:,1)).^2))/sum((Tsg2{j}(:,2)-
repmat(mean(Tsg2{j}(:,2)),size(Tsg2{j}(:,2))))).^2));
rrG2{j}=corrcoef(Tsg2{j}(:,1),Tsg2{j}(:,2));
mmG2(j,5)=rrG2{j}(2,1).^2;
mmG2(j,6)=mean(abs(Tsg2{j}(:,1)-Tsg2{j}(:,2))./Tsg2{j}(:,2));
```

```
%matriu indicadors ultima fila global
%mitjanes de balears de cada indicador
```

end

```
%mitjanes de balears de cada indicador
mmG(13,:)=mean(mmG(:,:));
mmG2(13,:)=mean(mmG2(:,:));
p={mm,mmG,mmT,mmG2,Tt,Tsg,Tt2,Tsg2,w,M1};
toc
```

6.6.10 Hgp2

```
function h=hgp2(M1,l)
%M1 ha de incloure es valors de Et0 de Pm calculats correctament
%(estacions final)
% l = a latituds
b=[9 21 10 11 13 24 27]; %filtram columnes d'interes (afegir alguna?)
M2=filtra2(M1,b);
M=M2{1};
% aquest programa calcula ETo amb els models de Hargreaves
for w=1:max(size(M1))
%col 17 Rs, col 7 Tmean
hg1{w}=0.0135*0.408*M{w}(:,21).*(M{w}(:,9)+17.8);

%distància inversa terra-sol
%col 6 dia julià ??
dr{w}=1+0.033*cos(2*pi*M{w}(:,8)/365);
%declinació solar
ds{w}=0.409*sin(2*pi*M{w}(:,8)/365-1.39);
%angle de radiació l'hora de la posta de sol
%col 22 lat??
```

```

ws{w}=acos(-tan(l(1,w)).*tan(ds{w})); %ws{w}=acos(-
tan(l(1,w)*pi/180).*tan(ds{w}));

%radiació extraterrestre
ra{w}=24*60*0.082*dr{w}/pi.*(ws{w}.*sin(l(1,w)).*sin(ds{w})+cos(l(1,w)).*co
s(ds{w}).*sin(ws{w}));
%col 8 Tmax col 9 Tmin
hg2{w}=0.0023*0.408*ra{w}.*(M{w}(:,9)+17.8).*(M{w}(:,10)-M{w}(:,11)).^0.5;
%col 10 HRmean?
hg3{w}=0.408*0.0135*0.338*ra{w}.*((M{w}(:,10)-M{w}(:,11)).^0.3).*((1.001-
M{w}(:,13)/100).^0.2).*(M{w}(:,9)+17.8);
h1{w}={hg1{w},hg2{w},hg3{w},dr{w},ds{w},ws{w},ra{w},M{w}};
for r=1:3
ahc{w}(:,r)=mean(M{w}(:,27)./h1{w}{r});

end
h2{w}={hg1{w}*ahc{w}(1,1),hg2{w}*ahc{w}(1,2),hg3{w}*ahc{w}(1,3)};

end

for t=1:3
for j=1:max(size(M1))
Tt{j}{t}=[h1{j}{t}, M{j}(:,27)]; %columna 27 es PM calculat
MSE(j,t)=mse(Tt{j}{t}(:,1)-Tt{j}{t}(:,2));
MSER(j,t)=(mse(Tt{j}{t}(:,1)-
Tt{j}{t}(:,2)))^0.5/nanmean(Tt{j}{t}(:,2));
MAE(j,t)=mae(Tt{j}{t}(:,1)-Tt{j}{t}(:,2));
NASH(j,t)=1-((nansum((Tt{j}{t}(:,2)-
Tt{j}{t}(:,1)).^2))/nansum((Tt{j}{t}(:,2)-
repmat(nanmean(Tt{j}{t}(:,2)),size(Tt{j}{t}(:,2))).^2)));
R2a{j}{t}=corrcoef(Tt{j}{t}(:,1),Tt{j}{t}(:,2));%,'rows','complete');
%%MIRAR , 3 VALORS NAN IMPEDEIXEN FER R2
R2(j,t)=R2a{j}{t}(2,1)^2; % Se eleva a dos?
AARE(j,t)=nanmean(abs(Tt{j}{t}(:,1)-Tt{j}{t}(:,2))./Tt{j}{t}(:,2));
MPE(j,t)=nanmean(Tt{j}{t}(:,1)-(Tt{j}{t}(:,2)));

%h{2}{j}(t,:)= [MSE{j}{t},MSER{j}{t},MAE{j}{t},NASH{j}{t},R2{j}{t},AARE{j}{t}
],MPE{j}{t}];

aTt{j}{t}=[h2{j}{t}, M{j}(:,27)]; %columna 27 es PM calculat
aMSE(j,t)=mse(aTt{j}{t}(:,1)-aTt{j}{t}(:,2));
aMSER(j,t)=(mse(aTt{j}{t}(:,1)-
aTt{j}{t}(:,2)))^0.5/nanmean(aTt{j}{t}(:,2));
aMAE(j,t)=mae(aTt{j}{t}(:,1)-aTt{j}{t}(:,2));
aNASH(j,t)=1-((nansum((aTt{j}{t}(:,2)-
aTt{j}{t}(:,1)).^2))/nansum((aTt{j}{t}(:,2)-
repmat(nanmean(aTt{j}{t}(:,2)),size(aTt{j}{t}(:,2))).^2)));

aR2a{j}{t}=corrcoef(aTt{j}{t}(:,1),aTt{j}{t}(:,2));%,'rows','complete');
%%MIRAR , 3 VALORS NAN IMPEDEIXEN FER R2
aR2(j,t)=aR2a{j}{t}(2,1)^2; % Se eleva a dos?
aAARE(j,t)=nanmean(abs(aTt{j}{t}(:,1)-aTt{j}{t}(:,2))./aTt{j}{t}(:,2));
aMPE(j,t)=nanmean(aTt{j}{t}(:,1)-(aTt{j}{t}(:,2)));

end
end

h{1}={ [MSE;mean(MSE)], [MSER;mean(MSER)], [MAE;mean(MAE)], [NASH;mean(NASH)], [
R2;mean(R2)], [AARE;mean(AARE)], [MPE;mean(MPE)] };

```

```

h{2}={ [aMSE;mean(aMSE) ], [aMSER;mean(aMSER) ], [aMAE;mean(aMAE) ], [aNASH;mean(a
NASH) ], [aR2;mean(aR2) ], [aAARE;mean(aAARE) ], [aMPE;mean(aMPE) ] };
h{3}=h1;
h{4}=h2;

```

6.6.11 Estàndard

```

function m=estandard(a)
for i=1:max(size(a))
    for j=9:min(size(a{i}))
m{1}(i,j-8)=nanstd(a{i}(:,j));
m{2}(i,j-8)=nanmean(a{i}(:,j));
end
end
%calcula les mitjanes de les diferents variables i les desviacions
%estandard d'aquestes

```

6.6.12 Arq

```

function m=arq(a)
for i=1:max(size(a{9}))

for j=1:max(size(a{9}{i}))
m{1}(j,i)=find(a{9}{i}{j}{3}{2}(2,:)==min(a{9}{i}{j}{3}{2}(2,:)));
m{2}(j,i)=find(a{9}{i}{j}{3}{7}(2,:)==min(a{9}{i}{j}{3}{7}(2,:)));
end
end
%Agafa els valors mes baixos de MSE , de C2 (conte els menors errors de cada
%arquitectura per cada any de test) en quant a CV

```

6.6.13 Anydetest

```

function m=anytest(a)
for i=1:max(size(a{9}))
    for j=1:max(size(a{9}{i}))
        m(i,j)=min(a{9}{i}{j}{3}{6}(2,:));

    end
end
%Agafa els menors errors de cada any de test (tria el menor error de totes
%les arquitectures per aquell any de test)

```

6.6.14 Càlcul de PM-56

```

% a= Cel.la amb es dades de les Estacions
% b=Coordenades
function p1=PMN(a,b)

%Pressió: Se calcula amb la matriu b(coordenades) i extreim la cota (12,i)
for i=1:max(size(b))

```

```
p1(1,i)=101.3*((293-0.0065*b(12,i)))/(293)^(5.26);  
end  
%calculam constant psicomètrica a partir de la Pressio (p1)  
for i=1:max(size(b))  
    y1(1,i)=0.665*10^-3*p1(1,i);  
end  
% -pendent de la corba de pressió de saturació de vapor amb Tmitjana
```


6.7 Instruments de mesura a les estacions del SIAR

6.7.1 Anemoveleta



Anemoveleta

Young 05103



Magnitudes Medidas:
Dirección del viento (°)
Velocidad del viento (m/s)

Características Técnicas
Alimentación: **Excitación del potenciómetro 15V max**
Consumo: **< 4mA @ 12V**
Señal de salida:
Velocidad de viento: **Pulsos (3 pulsos por revolución=8,8 m/s)**
Dirección de viento: **Voltaje**

Dirección del viento
Principio de funcionamiento: **Potenciómetro plástico conductivo de alta precisión de 10 KΩ de valor nominal. La señal de salida es una señal continua proporcional al ángulo medido**
Rango de medida: **0 – 360°**
Precisión: **± 3 °**

Velocidad de viento
Principio de funcionamiento: **La rotación de la hélice de 4 palas produce una señal eléctrica en corriente alterna, de frecuencia proporcional a la velocidad del viento**
Rango de medida: **0 – 100 m/s**
Precisión: **± 0,3 m/s**
Umbral mínimo de detección: **≤1,0 m/s máximo**



Pluviómetro

Campbell Scientific ARG100

Magnitudes Medidas:

Precipitación (mm)

Características Técnicas

Principio de funcionamiento: Sistema de cangilones basculantes

Señal de salida: Pulsos

Resolución: 0,2 mm por pulso

Precisión: $\pm 2\%$

Superficie cangilón: 506,5 cm²



6.7.3 Datalogger



Sistema de
Información Agroclimática
para el Regadío

Datalogger

Campbell Scientific CR10X



Imagen cedida por Campbell Scientific.

Funciones:

Registro de datos, medida de los sensores y control del funcionamiento de la estación.

Características Técnicas

Alimentación: 9,6 V a 16 V

Consumo:

1,3 mA en reposo

13 mA durante el proceso

46 mA durante las medidas analógicas

Temperatura de funcionamiento: -25°C a 50°C

Batería interna de litio para mantener los datos, el reloj y el programa en caso de que falle la alimentación.

Procesador

Convertidor analógico a digital de 13 bits

Procesador Hitachi 3606

750 Hz de tiempo mínimo de ejecución de programas

Puertos de medida

Entradas analógicas

6 entradas diferenciales o 12 entradas single – ended

Rango de voltajes medidos de 0 a $\pm 2,5$ V

6.7.4 Termohigrómetro



Sistema de
Información Agroclimática
para el Regadío

Termohigrómetro

Vaisala HMP45A

Magnitudes Medidas:

Temperatura del aire (°C)

Humedad del aire (% HR)



Características Técnicas

Alimentación: 7 – 35 VDC

Consumo: < 4mA @ 12V


Señal de salida: 0 – 1V

Temperatura

Principio de funcionamiento: **Termorresistencia de platino, Pt1000 IEC 751 1/3 Class B.**

Rango de medida: **-40 a 60 °C**

Precisión:



Humedad

Principio de funcionamiento: **Detector de polímero capacitivo Humicap® 180**

Rango de medida: **0-100 % HR**

Precisión: **± 2 % en el rango de 0 a 90 % HR ; ± 3 % en el rango de 90 a 100 % HR**

Dependencia de la temperatura en la medida de la humedad: **± 0,05 % HR / °C**

El sensor va montado en el interior de un protector, con ventilación natural, que protege la sonda de la radiación solar tanto directa como difusa, así como de la lluvia.



Sistema de
Información Agroclimática
para el Regadío

Piranómetro

Skye SP1110



Magnitudes Medidas:

Radiación Solar Global (W/m^2)

Características Técnicas

Principio de funcionamiento: **Fotocélula de silicio de baja fatiga**

Longitud de onda medida: **350 – 1.100 nm**

Rango de medida: **0 – 1370 W/m^2**

Precisión: **$\pm 5\%$**

Corrección del coseno: **0 para 0-70° y <10% para 85-90°**

Temperatura de trabajo: **-35 °C - 75 °C**

El sensor va montado sobre una base de nivelación y orientado al sur.

