


TESI DOCTORAL

Xavier Gavalrà Sanromà

**PREDICCIÓ DE
COEFICIENTS DE PRESSIÓ
MITJANÇANT
XARXES NEURONALS ARTIFICIALS**



UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Xavier Gavalrà Sanromà

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT
XARXES NEURONALS ARTIFICIALS

TESI DOCTORAL

Dirigida pel Dr. Francesc Giralt i Prat
i pel Dr. Joan Manel Ferrer i Gener

Departament d'Enginyeria Química



UNIVERSITAT ROVIRA I VIRGILI

Tarragona


2010

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010



UNIVERSITAT
ROVIRA I VIRGILI

ESCOLA TÈCNICA SUPERIOR D'ENGINYERIA QUÍMICA

Avinguda Països Catalans, 26

Campus Sescelades

43007 Tarragona

Tels. 977 55 97 00 - 977 55 97 07

Fax 977 55 96 99

www.etseq.urv.cat

Dr. Francesc Giralt i Prat, catedràtic d'universitat del Departament d'Enginyeria Química de la Universitat Rovira i Virgili, i el Dr. Joan Manel Ferrer i Gener, professor titular d'universitat del Departament d'Enginyeria Informàtica i Matemàtiques de la Universitat Rovira i Virgili,

CERTIFIQUEM:

Que aquest treball, titulat "Predicció de coeficients de pressió mitjançant xarxes neuronals artificials", que presenta el Sr. Xavier Gavalrà Sanromà per a l'obtenció del títol de Doctor, ha estat realitzat sota la nostra direcció al Departament d'Enginyeria Química d'aquesta universitat.

Tarragona, 23 de Novembre de 2009

Dr. Francesc Giralt i Prat

Dr. Joan Manel Ferrer i Gener

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Agraïments

A la meva família, en especial als meus pares Joan M^a i Matilde, als directors de la tesi Francesc i Joan, als companys de grup de recerca, de departament i d'escola. Als membres del tribunal per acceptar judicar aquest treball. Moltes gràcies a tots.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Índex

Resum	i
Llista de Figures	iii
Llista de Taules	xii
Capítol 1. Introducció	1
1.1 Motivació	1
1.2 Hipòtesis de treball	2
1.3 Antecedents	2
1.4 Objectius i estructura de la tesi	3
1.5 Referències	4
Capítol 2. Xarxes neuronals artificials	5
2.1 Introducció	5
2.2 Backpropagation (BP)	7
2.3 Self Organizing Maps (SOM)	10
2.4 Fuzzy Adaptive Resonance Theory (Fuzzy ARTMap)	15
2.5 Referències	19
Capítol 3. Resultats	21
Capítol 3A. Simulació de sèries temporals de coeficients de pressió sobre un cilindre en condicions altament turbulentes	23
3A.1 Introducció	23
3A.2 Dades experimentals	24
3A.3 Anàlisi de les dades experimentals	25
3A.4 Característiques de les xarxes neuronals artificials emprades (ANN)	31
3A.5 Resultats	32
3A.6 Conclusions	38
Capítol 3B. Classificació i reconstrucció de series temporals de coeficients de pressió sobre un cilindre en condicions altament turbulentes	39
3B.1 Introducció	39
3B.2 Dades experimentals	40

3B.3	Característiques de les xarxes neuronals artificials emprades (ANN)	40
3B.4	Generació de les sèries temporals	41
3B.5	Resultats	42
3B.5.1	Validació de la metodologia emprada.	50
3B.6	Conclusions	53
Capítol 3C.	Interpolació de coeficients de pressió sobre teulades de cases prefabricades de baixa alçada	55
3C.1	Introducció	55
3C.2	Dades experimentals	56
3C.2.1	Models a escala	56
3C.2.2	Distribució dels sensors de pressió	57
3C.2.3	Simulació de les condicions de vent	59
3C.2.4	Obtenció dels conjunts de dades	60
3C.3	Desenvolupament dels models d'interpolació	61
3C.3.1	Model 1. Diferents dimensions de teulada	62
3C.3.1.1	Selecció de variables	62
3C.3.1.2	Disseny de les xarxes neuronals artificials	65
3C.3.1.3	Primers resultats obtinguts i selecció del conjunt de variables d'entrada	68
3C.3.1.4	Característiques finals de les ANN emprades per al model d'interpolació	74
3C.3.1.5	Comprovació de l'eficàcia del model	76
3C.3.2	Model 2. Diferents pendents de teulada	99
3C.3.2.1	Selecció de variables	99
3C.3.2.2	Disseny de les xarxes neuronals artificials	100
3C.3.2.3	Característiques finals de les ANN emprades per al model d'interpolació	101
3C.3.2.4	Comprovació de l'eficàcia del model	103
3C.4	Conclusions	126
3.1	Referències	127
Capítol 4.	Conclusions	129
Capítol 5.	Treball futur i recomanacions	131
Annexos		133

Resum

Els coeficients de pressió són una mesura adimensional que relaciona les forces inercials d'un fluid amb les forces de pressió. L'ús principal és en el camp de l'aerodinàmica, ja que el seu valor sobre la superfície d'un cos és independent de les dimensions del cos en qüestió. Aquesta característica permet testar models a escala en túnels de vent, tot calculant els coeficients de pressió en els punts crítics sobre la superfície del cos que s'estudia (per exemple, l'ala d'un avió) i extrapolant-ne els valors a un model a escala real.

Quan es treballa amb fluxos turbulents, les equacions que governen l'evolució temporal dels fluids ja no es poden resoldre de forma analítica. Actualment, aquest problema s'intenta solucionar mitjançant la resolució numèrica d'aquestes equacions, però, depenent del cas, la càrrega computacional que implica complica enormement la tasca. En aquest treball, s'opta per una alternativa relativament nova comparada amb els mètodes tradicionals. Es tracta de les xarxes neuronals artificials (ANN). Les ANN són models de "caixa negra", és a dir, són capaces de relacionar entrades amb sortides sense la necessitat de conèixer les equacions que governen el sistema per modelar. La capacitat que tenen de trobar relacions complexes i altament no lineals les fa especialment útils per treballar amb fluxos turbulents.

En aquesta tesi es desenvolupen models de predicció de coeficients de pressió emprant xarxes neuronals artificials. Començant amb la simulació d'un sistema dinàmic compost per un cilindre circular immers en condicions altament turbulentes, es demostra que les dades de pressió són suficients perquè les ANN puguin capturar la dinàmica d'un sistema turbulent durant un entrenament previ i reproduir-lo *a posteriori*. L'estudi d'aquest primer sistema dinàmic assenta les bases per treballar en la interpolació d'una extensa base de dades de coeficients de pressió sobre models a escala de cases prefabricades de baixa alçada. El disseny de les teulades de les cases prefabricades de baixa alçada es realitza a partir de les dades obtingudes en túnels de vent on es treballa amb models a escala. Per molt extensa que sigui una base de dades, sempre hi ha casos que no han estat estudiats, i, per tant, és molt útil disposar d'un model que sigui capaç d'interpol·lar, de forma precisa, nous casos a partir de les dades de què ja es disposa. Una correcta selecció i pretractament de les variables que intervenen en el sistema i el disseny òptim de les ANN ha permès millorar l'eficàcia dels models d'interpolació (de coeficients de pressió sobre teulades de cases prefabricades de baixa alçada) existents fins ara.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Llistat de figures

Figura 2.1	Esquema d'una neurona artificial.	5
Figura 2.2	Xarxa multicapa amb estructura 2:3:1 (capa d'entrada <i>I</i> de dues entrades, capa oculta <i>H</i> amb 3 neurones i capa de sortida <i>O</i> amb 1 neurona).	8
Figura 2.3	Descripció detallada del funcionament de cada neurona.	8
Figura 2.4	Esquema d'una xarxa SOM de dimensions 6×6 amb n entrades.	11
Figura 2.5	Graella per a mapa (segona capa de neurones) SOM de tipus <i>a</i>) quadrada i <i>b</i>) hexagonal.	12
Figura 2.6	Exemple d'una U-matrix on es poden distingir clarament dues zones o clústers separats per distàncies elevades entre neurones.	13
Figura 2.7	Exemple d'una representació de les quatre dimensions dels vectors SOM d'un mapa de dimensions 10×10 destinat a un Principal Component Analysis.	15
Figura 2.8	Esquema de l'arquitectura d'una xarxa Fuzzy ARTMap.	16
Figura 3A.1	Esquema del cilindre.	24
Figura 3A.2	Distribució dels sensors al voltant del cilindre.	24
Figura 3A.3	Flux al voltant d'un cilindre circular submergit en un fluid (Zdravkovich, 1997).	26
Figura 3A.4	Valors experimentals de la <i>a</i>) mitjana i la <i>b</i>) desviació estàndard dels coeficients de pressió per a cada sensor sobre la superfície del cilindre.	27
Figura 3A.5	Densitat espectral de potència de la desviació estàndard del coeficient de sustentació vs la freqüència de la presa de mesures experimentals.	28
Figura 3A.6	Valors experimentals del coeficient de pressió per als sensors situats als angles 0° i 101° .	28
Figura 3A.7	Autocorrelació de les dades experimentals per al sensor situat al punt d'estancament (0°).	29

Figura 3A.8	Correlació espacial de tres sensors (situats a les posicions 0° , 101° i 180°) amb la resta de sensors situats sobre la superfície d'un cilindre circular.	30
Figura 3A.9	Esquema d'una combinació patró d'entrada/sortida.	31
Figura 3A.10	Desviació estàndard dels coeficients de pressió (C_p) estimats per les xarxes comparats amb els valors experimentals.	34
Figura 3A.11	Correlació espacial experimental i estimada del sensor situat a la posició a) 0° i b) 101° respecte a la resta de sensors situats sobre la superfície d'un cilindre circular.	35
Figura 3A.12	Correlació espacial experimental i estimada del sensor situat a 90° respecte a la resta de sensors situats sobre la superfície d'un cilindre circular.	35
Figura 3A.13	Autocorrelació experimental i estimada del sensor situat a la posició a) 0° i b) 101° .	37
Figura 3A.14	<i>Skewness</i> dels coeficients de pressió estimats (per la xarxa FAM32,4,4) i experimentals per a cada sensor situat sobre la superfície del cilindre circular.	37
Figura 3B.1	Valors del a) <i>skewness</i> i b) de les sèries temporals de C_p experimentals i generades a les quatre clusteritzacions realitzades compostes per 1) 9 clústers, 2) 17 clústers, 3) 22 clústers i 4) 25 clústers per al conjunt de dades amb $Re = 1,0 \times 10^6$.	47
Figura 3B.2	Autoespectres de les sèries experimentals i generades de coeficients de pressió corresponents als sensors 1) #7, 2) #12, 3) #19 i 4) #22 emprant la clusterització amb 22 clústers per al conjunt de dades amb $Re = 1,0 \times 10^6$.	48
Figura 3B.3	Valors de a) <i>skewness</i> i b) curtosi de les sèries temporals de C_p experimentals i generades a conjunts de dades amb 1) $Re = 4,5 \times 10^5$ i 2) $Re = 2,2 \times 10^5$.	52
Figura 3C.1	Esquema d'un pendent 3:12 on es mostra que per a cada 12 unitats horitzontals, se'n pugen 3.	57
Figura 3C.2	Exemple d'un dels models a escala situat al túnel de vent.	57
Figura 3C.3	Esquema de la distribució dels sensors (+) sobre la teulada dels models a escala.	58
Figura 3C.4	Imatge real de la distribució dels sensors sobre la teulada dels models a escala.	58

Figura 3C.5	Imatge del túnel de vent on es veu el model a escala en primer pla, els blocs metàl·lics a continuació i les tres agulles amb la barrera travessera al fons.	59
Figura 3C.6	Imatge dels objectes destinats a crear la turbulència a l'entrada del túnel de vent (vist en direcció aigües amunt).	61
Figura 3C.7	Esquema de les variables que intervenen en el model 1.	62
Figura 3C.8	Exemple gràfic de la funció del preprocesament de les coordenades espacials x i y .	63
Figura 3C.9	Representació en SOM de les 10 possibles variables que s'empraran en els vectors d'entrada de l'ANN.	65
Figura 3C.10	Representació d'una funció de transferència <i>a)</i> logarítmica sigmoïdal i <i>b)</i> tangent sigmoïdal.	67
Figura 3C.11	Representació d'una funció de transferència lineal.	67
Figura 3C.12	Coefficient de correlació de Pearson (R) entre la predicció de la xarxa Backpropagation i els valors experimentals per a cada combinació de variables d'entrada.	70
Figura 3C.13	Comparació de l'eficiència de les xarxes en funció del tipus de normalització realitzada a les coordenades espacials x i y per a combinacions de variables d'entrada <i>a)</i> sense emprar la coordinada espacial z i <i>b)</i> emprant-la.	70
Figura 3C.14	Comparació de l'eficiència de les xarxes en funció de l'ús o no de la coordinada espacial z per a combinacions de variables d'entrada que empren <i>a)</i> x i y , <i>b)</i> x i y^* i <i>c)</i> x_n, y_n .	71
Figura 3C.15	Comparació de l'eficiència de les xarxes en funció de l'ús o no de l'alçada de la base de la teulada (H) com a variable en el conjunt d'entrades de la xarxa.	71
Figura 3C.16	Comparació de l'eficiència de les xarxes en funció de l'ús de l'alçada de la base de la teulada (H) o de la coordinada espacial z , com a variable en el conjunt d'entrades de la xarxa.	72
Figura 3C.17	Comparació de l'eficiència de les xarxes en funció de l'ús o no de les dimensions de teulada (X i Y) com a variables en el conjunt d'entrades de la xarxa.	72
Figura 3C.18	Representació gràfica de la xarxa descrita a la taula 3C.7.	75
Figura 3C.19	Representació gràfica de la xarxa descrita a la taula 3C.8.	75

Figura 3C.20	Representació de la posició del sensor situat a la cantonada de la teulada (requadre negre petit) i de la <i>corner bay</i> (requadre negre gran).	77
Figura 3C.21.1	Distribució de \bar{C}_p sobre una teulada de dimensions 19,1 m × 12,9 m, alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 280° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	79
Figura 3C.21.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 19,1 m × 12,9 m, alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 280° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	79
Figura 3C.22.1	Distribució de \bar{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 300° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	80
Figura 3C.22.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 300° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	80
Figura 3C.23.1	Distribució de \bar{C}_p sobre una teulada de dimensions 76,2 m × 48,8 m, alçada de la base de la teulada de 12,19 m i angle d'incidència del vent de 320° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	81
Figura 3C.23.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 76,2 m × 48,8 m, alçada de la base de la teulada de 12,19 m i angle d'incidència del vent de 320° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	81
Figura 3C.24.1	Distribució de \bar{C}_p sobre una teulada de dimensions 57,2 m × 36,6 m, alçada de la base de la teulada de 12,19 m i angle d'incidència del vent de 340° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	82

Figura 3C.24.2	Distribució de \bar{C}_p sobre una teulada de dimensions 57,2 m × 36,6 m, alçada de la base de la teulada de 12,19 m i angle d'incidència del vent de 340° a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	82
Figura 3C.25	Força de sustentació a la <i>corner bay</i> , calculada amb dades experimentals del túnel de vent, per a tots els models a escala i angles d'incidència del vent per a una alçada de la base de la teulada de 7,32 m.	85
Figura 3C.26	Força de sustentació a la <i>corner bay</i> , calculada amb les dades experimentals dels models de teulada A, B, C i D i les dades generades per les ANN per als models G, H i I per a tots els angles d'incidència del vent i una alçada de la base de la teulada de 7,32 m.	86
Figura 3C.27.1	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 270°, alçada de la base de la teulada de 7,32 m i unes dimensions de <i>a</i>) 19,1 m × 12,9 m (dades experimentals), <i>b</i>) 28,6 m × 18,3 m (dades estimades) i <i>c</i>) 38,1 m × 24,2 m (dades experimentals).	87
Figura 3C.27.2	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 295°, alçada de la base de la teulada de 12,19 m i unes dimensions de <i>a</i>) 38,1 m × 24,2 m (dades experimentals), <i>b</i>) 47,6 m × 30,5 m (dades estimades) i <i>c</i>) 57,2 m × 36,6 m (dades experimentals).	88
Figura 3C.27.3	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 315°, alçada de la base de la teulada de 7,32 m i unes dimensions de <i>a</i>) 57,2 m × 36,6 m (dades experimentals), <i>b</i>) 66,7 m × 42,7 m (dades estimades) i <i>c</i>) 76,2 m × 48,8 m (dades experimentals).	88
Figura 3C.27.4	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 335°, alçada de la base de la teulada de 7,32 m i unes dimensions de <i>a</i>) 38,1 m × 24,2 m (dades experimentals), <i>b</i>) 47,6 m × 30,5 m (dades estimades) i <i>c</i>) 57,2 m × 36,6 m (dades experimentals).	89
Figura 3C.27.5	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 360°, alçada de la base de la teulada de 12,19 m i unes dimensions de <i>a</i>) 19,1 m × 12,9 m (dades experimentals), <i>b</i>) 28,6 m × 18,3 m (dades estimades) i <i>c</i>) 38,1 m × 24,2 m (dades experimentals).	89

Figura 3C.28.1	Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 285° , alçada de la base de la teulada de 12,19 m i unes dimensions de <i>a</i>) 19,1 m \times 12,9 m (dades experimentals), <i>b</i>) 28,6 m \times 18,3 m (dades estimades) i <i>c</i>) 38,1 m \times 24,2 m (dades experimentals).	90
Figura 3C.28.2	Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 310° , alçada de la base de la teulada de 7,32 m i unes dimensions de <i>a</i>) 38,1 m \times 24,2 m (dades experimentals), <i>b</i>) 47,6 m \times 30,5 m (dades estimades) i <i>c</i>) 57,2 m \times 36,6 m (dades experimentals).	91
Figura 3C.28.3	Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 345° , alçada de la base de la teulada de 12,19 m i unes dimensions de <i>a</i>) 57,2 m \times 36,6 m (dades experimentals), <i>b</i>) 66,7 m \times 42,7 m (dades estimades) i <i>c</i>) 76,2 m \times 48,8 m (dades experimentals).	91
Figura 3C.29.1	Autoespectre de la força de sustentació sobre una teulada de dimensions 19,1 m \times 12,9 m, alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 280° .	97
Figura 3C.29.2	Autoespectre de la força de sustentació sobre una teulada de dimensions 38,1 m \times 24,4 m, alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 300° .	98
Figura 3C.29.3	Autoespectre de la força de sustentació sobre una teulada de dimensions 76,2 m \times 48,8 m, alçada de la base de la teulada de 12,19 m i angle d'incidència del vent de 320° .	98
Figura 3C.29.4	Autoespectre de la força de sustentació sobre una teulada de dimensions 57,2 m \times 36,6 m, alçada de la base de la teulada de 12,19 m i angle d'incidència del vent de 340° .	99
Figura 3C.30	Representació gràfica de la xarxa descrita a la taula 3C.13.	102
Figura 3C.31	Representació gràfica de la xarxa descrita a la taula 3C.14.	102
Figura 3C.32.1	Distribució de \bar{C}_p sobre una teulada de dimensions 38,1 m \times 24,4 m, alçada de la base de la teulada de 12,19 m, angle d'incidència del vent de 280° i pendent de teulada de $\frac{1}{4}:12$ a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	105
Figura 3C.32.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 38,1 m \times 24,4 m, alçada de la base de la teulada de 12,19 m, angle d'incidència del vent de 280° i pendent de teulada de $\frac{1}{4}:12$ a partir de dades <i>a</i>) estimades per l'ANN i <i>b</i>) experimentals provinents del túnel de vent.	105

Figura 3C.33.1	Distribució de \bar{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m, angle d'incidència del vent de 300° i pendent de teulada de 1:12 a partir de dades <i>a)</i> estimades per l'ANN i <i>b)</i> experimentals provinents del túnel de vent.	106
Figura 3C.33.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m, angle d'incidència del vent de 300° i pendent de teulada de 1:12 a partir de dades <i>a)</i> estimades per l'ANN i <i>b)</i> experimentals provinents del túnel de vent.	106
Figura 3C.34.1	Distribució de \bar{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m, angle d'incidència del vent de 320° i pendent de teulada de 3:12 a partir de dades <i>a)</i> estimades per l'ANN i <i>b)</i> experimentals provinents del túnel de vent.	107
Figura 3C.34.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m, angle d'incidència del vent de 320° i pendent de teulada de 3:12 a partir de dades <i>a)</i> estimades per l'ANN i <i>b)</i> experimentals provinents del túnel de vent.	107
Figura 3C.35.1	Distribució de \bar{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 12,19 m, angle d'incidència del vent de 340° i pendent de teulada de 3:12 a partir de dades <i>a)</i> estimades per l'ANN i <i>b)</i> experimentals provinents del túnel de vent.	108
Figura 3C.35.2	Distribució de \tilde{C}_p sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 12,19 m, angle d'incidència del vent de 340° i pendent de teulada de 3:12 a partir de dades <i>a)</i> estimades per l'ANN i <i>b)</i> experimentals provinents del túnel de vent.	108
Figura 3C.36	Força de sustentació a la <i>corner bay</i> , calculada amb les dades experimentals dels models de teulada A, E i F i les dades generades per les ANN per als models J, K i L per a tots els angles d'incidència del vent i una alçada de la base de la teulada de 7,32 m.	115
Figura 3C.37.1	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 285°, alçada de la base de la teulada de 7,32 m i un pendent de <i>a)</i> 1:12 (dades experimentals), <i>b)</i> 2:12 (dades estimades) i <i>c)</i> 3:12 (dades experimentals).	117

Figura 3C.37.2	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 300° , alçada de la base de la teulada de 12,19 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	116
Figura 3C.37.3	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 315° , alçada de la base de la teulada de 7,32 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	117
Figura 3C.37.4	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 330° , alçada de la base de la teulada de 12,19 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	117
Figura 3C.37.5	Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 330° , alçada de la base de la teulada de 7,32 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	118
Figura 3C.38.1	Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 280° , alçada de la base de la teulada de 12,19 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	119
Figura 3C.38.2	Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 305° , alçada de la base de la teulada de 7,32 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	119
Figura 3C.38.3	Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 345° , alçada de la base de la teulada de 12,19 m i un pendent de <i>a</i>) 1:12 (dades experimentals), <i>b</i>) 2:12 (dades estimades) i <i>c</i>) 3:12 (dades experimentals).	120
Figura 3C.39.1	Autoespectre de la força de sustentació sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 12,19 m, angle d'incidència del vent de 280° i pendent de teulada $\frac{1}{4}$:12.	124
Figura 3C.39.2	Autoespectre de la força de sustentació sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m, angle d'incidència del vent de 300° i pendent de teulada 1:12.	125
Figura 3C.39.3	Autoespectre de la força de sustentació sobre una teulada de dimensions 38,1 m × 24,4 m, alçada de la base de la teulada de 7,32 m, angle d'incidència del vent de 320° i pendent de teulada 3:12.	125

- Figura 3C.39.4 Autoespectre de la força de sustentació sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 340° i pendent de teulada 3:12. 126

Llistat de taules

Taula 3A.1	Resum de la combinació de dades temporals i espacials emprades en els patrons d'entrada al mòdul ART ^a .	32
Taula 3A.2	Error en la predicció de la desviació estàndard dels coeficients de pressió, sustentació i arrossegament per a cada arquitectura de xarxa emprada.	33
Taula 3B.1	Clusterització dels trenta-dos patrons del conjunt de dades amb $Re = 1,0 \times 10^6$ emprant a) 9 clústers, b) 17 clústers, c) 22 clústers i d) 25 clústers.	44
Taula 3B.2	Càrregues aerodinàmiques calculades a partir de la combinació de sèries temporals de C_p experimentals i generades per a les quatre clusteritzacions realitzades per al conjunt de dades amb $Re = 1,0 \times 10^6$.	44
Taula 3B.3	Error relatiu de la desviació estàndard dels coeficients de sustentació i arrossegament per a les 4 clusteritzacions realitzades per al conjunt de dades amb $Re = 1,0 \times 10^6$.	45
Taula 3B.4	Error absolut mitjà entre els valors dels <i>skewness</i> i la curtosi de les sèries experimentals i generades de C_p per a les 4 clusteritzacions per al conjunt de dades amb $Re = 1,0 \times 10^6$.	47
Taula 3B.5	Clusterització afinada dels trenta-dos patrons del conjunt de dades amb $Re = 1,0 \times 10^6$.	49
Taula 3B.6	Error relatiu i valors de la desviació estàndard dels coeficients de sustentació i arrossegament per a la clusterització afinada realitzada per al conjunt de dades amb $Re = 1,0 \times 10^6$.	49
Taula 3B.7	Error absolut i valors de l' <i>skewness</i> i la curtosi de les sèries temporals de C_p experimentals i generades per als 7 sensors generats en la clusterització afinada per al conjunt de dades amb $Re = 1,0 \times 10^6$.	49
Taula 3B.8	Clusterització dels trenta-dos patrons del conjunt de dades amb a) $Re = 4,5 \times 10^5$ i b) $Re = 2,2 \times 10^5$.	51
Taula 3B.9	a) Càrregues aerodinàmiques calculades a partir de la combinació de sèries temporals de C_p experimentals i generades per als conjunts de dades amb $Re = 4,5 \times 10^5$ i $Re = 2,2 \times 10^5$ i b) error relatiu de la desviació estàndard en el càlcul dels coeficients de sustentació i arrossegament.	51

Taula 3C.1	Pendent i dimensions de les teulades dels sis models a escala emprats en el túnel de vent.	56
Taula 3C.2	Característiques dels conjunts de dades experimentals emprades en cada model.	62
Taula 3C.3	Combinació de variables d'entrada emprades i la seva corresponent nomenclatura de referència.	66
Taula 3C.4	Resultats de la millor predicció de \bar{C}_p per a cada combinació de variables d'entrada per a xarxes amb un màxim de 10 neurones per capa oculta ($n1$).	69
Taula 3C.5	Resultats de la millor predicció de \tilde{C}_p per a cada combinació de variables d'entrada per a xarxes amb un màxim de 10 neurones per capa oculta ($n1$).	73
Taula 3C.6	Resultats de la millor predicció de \bar{C}_p i \tilde{C}_p per a cada combinació de variables d'entrada per a xarxes amb un màxim de 20 neurones per capa oculta ($n2$).	74
Taula 3C.7	Paràmetres de la xarxa Backpropagation destinada a la predicció de \bar{C}_p per al model 1.	74
Taula 3C.8	Paràmetres de la xarxa Backpropagation destinada a la predicció de \tilde{C}_p per al model 1.	75
Taula 3C.9	Error de predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada i RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la <i>corner bay</i> .	78
Taula 3C.10	Error en la predicció de la força de sustentació \bar{F}_s sobre la superfície de la <i>corner bay</i> per a cadascun dels 32 conjunts de dades no emprats en l'entrenament de l'ANN.	84
Taula 3C.11	Característiques dels nous conjunts de dades generades pel model 1.	86
Taula 3C.12.1	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala A (38,1 m × 24,4 m).	93
Taula 3C.12.2	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala B (19,1 m × 12,9 m).	94
Taula 3C.12.3	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada	95

	del model a escala C (76,2 m × 48,8 m).	
Taula 3C.12.4	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala D (57,2 m × 36,6 m).	96
Taula 3C.13	Paràmetres de la xarxa Backpropagation destinada a la predicció de \bar{C}_p per al model 2.	101
Taula 3C.14	Paràmetres de la xarxa Backpropagation destinada a la predicció de \tilde{C}_p per al model 2.	102
Taula 3C.15	Error de predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada i RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la <i>corner bay</i> .	104
Taula 3C.16	Error en la predicció de la força de sustentació \bar{F}_s sobre la superfície de la <i>corner bay</i> per a cadascun dels 24 conjunts de dades no emprats en l'entrenament de l'ANN.	110
Taula 3C.17	Característiques dels nous conjunts de dades generades pel model 2.	110
Taula 3C.18	Paràmetres de la xarxa Backpropagation destinada a la predicció de \bar{C}_p per al model 2B.	112
Taula 3C.19	Paràmetres de la xarxa Backpropagation destinada a la predicció de \tilde{C}_p per al model 2B.	112
Taula 3C.20	Error de predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada i RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la <i>corner bay</i> .	113
Taula 3C.21	Error en la predicció de la força de sustentació \bar{F}_s sobre la superfície de la <i>corner bay</i> per a cadascun dels 24 conjunts de dades no emprats en l'entrenament de l'ANN.	114
Taula 3C.22.1	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala A (pendent 1:12).	121
Taula 3C.22.2	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala E (pendent 1/4:12).	122
Taula 3C.22.3	Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala F (pendent 3:12).	123

Capítol 1. Introducció

1.1 Motivació

La simulació de fluxos turbulents és imprescindible en el disseny d'edificis, ponts, avions i qualsevol altra estructura exposada al vent. A diferència dels fluxos laminars, en què l'ordre present en la seva estructura permet desenvolupar models matemàtics senzills basats en les propietats físiques del sistema, en els fluxos turbulents aquest ordre no existeix.

Un dels casos pràctics de la simulació de fluxos turbulents és l'aplicació en el disseny de teulades de cases prefabricades de baixa alçada. La fabricació en sèrie i amb materials econòmics, com la fusta, abarateixen de forma considerable el cost de l'habitatge, però com a contrapartida, l'estabilitat davant condicions climàtiques adverses, amb forts vents, es veu reduïda. La demanda de cases prefabricades va en augment, i més en temps de crisi econòmica. Només als Estats Units i al Canadà se n'hi arriben a construir fins a dos milions cada any.

Actualment, el disseny de cases prefabricades de baixa alçada es realitza seguint els estàndards que fixen l'American Society of Civil Engineers (ASCE, 2002) i la National Research Council Canada (NRCC, 1995) que al seu temps estan basats, en gran manera, en els experiments realitzats en túnels de vent a la Universitat de Western Ontario (UWO), al Canadà, a partir de finals dels anys setanta (Stathopoulos, 1979). Avui en dia hi ha un major coneixement de l'aerodinàmica d'aquest tipus de cases, així com una millora de les tècniques de simulació a escala en túnels de vent, fet que ha dut la UWO a col·laborar en un ambiciós projecte iniciat per la Universitat Texas Tech (TTU) i el United States National Institute of Standards and Technology (NIST), consistent en la realització d'una base de dades sobre càrregues de vent en edificis prefabricats d'alçada baixa (Ho et al., 2005; St. Pierre, 2005).

La simulació en túnels de vent és un procés laboriós i car, i el nombre de configuracions de teulades possible és gairebé infinit; així que per molt àmplia que sigui la base de dades de què es disposi, sempre hi haurà casos que no hi seran presents. Aquest fet és el que motiva la realització de models que siguin capaços d'interpol·lar dins de les bases de dades existents i extreure'n dades per a casos dels quals no es tenen dades experimentals.

1.2 Hipòtesis de treball

Aquest treball es basa en una sèrie d'hipòtesis que es validen a mesura que s'avança en el desenvolupament del model final d'interpolació de la base de dades del NIST. Aquesta base de dades consta de centenars de conjunts de dades compostos per sèries temporals de pressió sobre models a escala de cases prefabricades de baixa alçada.

La primera hipòtesi és que les dades de pressió sobre la superfície d'un cos contenen, en si mateixes, prou informació perquè un model matemàtic pugui reproduir l'evolució temporal d'un flux turbulent, sense la necessitat de disposar de més dades sobre el flux.

La segona hipòtesi emprada es basa en el fet que les xarxes neuronals artificials (ANN, de l'anglès Artificial Neural Networks) poden capturar comportaments estocàstics com ho és el d'un flux turbulent. La principal característica d'un model realitzat amb ANN és que es capaç de trobar una relació causa-efecte a partir, únicament, de dades històriques d'un procés, independentment del coneixement de les lleis físiques que el governen.

La combinació d'ambdues hipòtesis suposa la possibilitat de crear models de predicció/interpolació de dades de pressió, sobre la superfície d'un cos, en condicions de flux turbulent. Les dades de pressió permeten el càlcul de càrregues aerodinàmiques a les quals està sotmès un cos, objectiu últim del model.

1.3 Antecedents

Són diverses les possibles aproximacions que s'han fet en la predicció de sèries temporals de pressió. Algunes empenen mètodes estadístics, com són els treballs de Gioffrè et al. (2000, 2001) o els de Gurley et al. (1997) i Popescu et al. (1998), en els quals estimen funcions de probabilitat de densitat i de covariància per realitzar les prediccions. En aquest treball s'ha escollit l'ús de les ANN basant-se en treballs previs en què l'ús de models de predicció, basats en xarxes neuronals artificials, han aportat bons resultats. En primer lloc, hi ha el treball de Giralt et al. (2000), en què van predir satisfactòriament camps instantanis de velocitat dins l'estela creada per un cilindre emprant ANN. En segon lloc, hi ha els treballs de Chen et al. (2003a, 2003b), que, treballant ja amb les bases de dades del NIST, van crear models d'interpolació per a un limitat nombre de variables físiques dels models a escala. El treball de Giralt et al. serveix de base per a la realització de la primera part presentada en aquesta tesi, mentre que el gruix de la tesi, que és el desenvolupament del model d'interpolació de la base de dades del NIST, és una ampliació i perfeccionament dels treballs previs de Chen et al.

1.4 Objectius i estructura de la tesi

L'objectiu principal de la tesi és el de crear un model d'interpolació, basat en xarxes neuronals artificials, que sigui capaç de proporcionar sèries temporals de pressions, sobre la superfície de les teulades de cases prefabricades de baixa alçada, per a les configuracions físiques de teulada desitjades. La predicció de les sèries temporals de pressions té com a objectiu final el càlcul de les càrregues aerodinàmiques que suportarà la teulada i, per tant, proporcionar les dades necessàries per a un disseny òptim.

Per validar les hipòtesis de treball esmentades, es comença treballant amb un sistema més senzill que el dels models a escala de les cases prefabricades. Aquest sistema és el d'un cilindre immers en condicions de vent altament turbulent ($Re = 10^6$). S'ha escollit aquest sistema per diversos motius. En primer lloc, perquè és el sistema emprat per Giralt et al. en el treball comentat en l'anterior secció, tot i que en condicions d'operació molt diferents. En segon lloc, perquè, tot i que el cilindre presenta una forma geomètrica molt senzilla, l'estructura del flux al seu voltant, en les condicions altament turbulentes amb què es treballa, presenta una gran complexitat, comparable amb la que es trobarà més endavant, en el cas dels models a escala de les cases prefabricades. I, en tercer lloc, perquè el volum de dades experimentals amb les quals es treballa és molt inferior que en el cas de les cases prefabricades i permet fer una primera validació de les hipòtesis de treball de forma més còmoda.

En els següents capítols es presenten les metodologies seguides i desenvolupades per modelitzar les pressions en fluxos turbulents, així com casos pràctics en els quals s'han aplicat.

Al capítol 2 hi ha una introducció al camp de les xarxes neuronals artificials, començant amb una breu cronologia de la història d'aquest camp, seguida d'una caracterització dels diferents tipus de xarxes existents i, finalment, una descripció detallada dels tres tipus de xarxes utilitzades en aquest treball.

El capítol 3 presenta el nus de la tesi, amb tres divisions ben clares que corresponen als tres treballs que conglomeren la feina realitzada durant el període d'elaboració de la tesi. Cada un dels tres subcapítols està organitzat com un treball individual, amb una introducció, desenvolupament de la metodologia emprada, presentació de resultats i conclusions. Els dos primers subcapítols empen el sistema dinàmic del cilindre per validar les hipòtesis de treball i desenvolupar part de la metodologia que cal seguir en el tercer subcapítol, en què ja es treballa amb els models a escala de les cases prefabricades i es desenvolupa el model d'interpolació de la base de dades del NIST.

El capítol 4 resumeix i engloba les conclusions extretes en els tres subcapítols del capítol 3, i el capítol 5 perfila els futurs treballs que es poden derivar del conjunt d'aquesta tesi.

1.5 Referències

ASCE (2002). *ASCE 7-02. Minimum design loads for buildings and other structures. Revision of ANSI/ASCE 7-98*. Reston.

CHEN, Y.; G. A. KOPP; D. SURRY (2003a). “Interpolation of pressure time series in an aerodynamic database for low buildings”, *J. Wind. Eng. Ind. Aerodyn.* 91, 737-765.

— (2003b). “Prediction of pressure coefficients on roofs of low buildings using artificial neural networks”, *J. Wind. Eng. Ind. Aerodyn.* 91, 423-441.

GIOFFRÈ, M.; V. GUSELLA; M. GRIGORIU (2000). “Simulation of non-Gaussian field applied to wind pressure fluctuations”, *Probab. Eng. Mech.* 15, 339-345.

— (2001). “Non-Gaussian wind pressure on prismatic buildings. II. numerical simulation”, *J. Struct. Eng.* 127 (9), 990-995.

GIRALT, F.; A. ARENAS; J. FERRÉ-GINÉ; R. RALLO; G. A. KOPP (2000). “The simulation and interpretation of turbulence with a cognitive neural system”, *Phys Fluids* 12, 1826.

GURLEY, K.; M. A. TOGNARELLI; A. KAREEM (1997). “Analysis and simulation tools for wind engineering”, *Probab. Eng. Mech.* 12 (1), 9-31.

HO, T. C. E.; D. SURRY; D. MORRISH; G. A. KOPP (2005). “The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part I. Archiving format and basic aerodynamic data”, *J. Wind. Eng. Ind. Aerodyn.* 93, 1-30.

METAL BUILDING MANUFACTURERS ASSOCIATION (MBMA) (1996). *Metal building systems manual*. Cleveland: MBMA.

NATIONAL RESEARCH COUNCIL CANADA (NRCC) (1995). *The supplement to the National Building Code of Canada*. Ottawa: NRCC.

POPESCU, R.; G. DEODATIS; J. H. PREVOST (1998). “Simulation of homogeneous non-Gaussian stochastic vector fields”, *Probab. Eng. Mech.* 13, 1-13.

ST. PIERRE, L. M.; G. A. KOPP; D. SURRY; T. C. E. HO (2005). “The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 2. Comparison of data with wind load provisions for low buildings”, *J. Wind. Eng. Ind. Aerodyn.* 93, 31-59.

STATHOPOULOS, T. (1979). “Turbulent wind action on low-rise buildings”. *Ph. D. Thesis* (Londres, Canadà). Universitat de Western Ontario.

Capítol 2. Xarxes neuronals artificials

2.1 Introducció

Des que l'home ha descobert els fonaments del funcionament del cervell humà, ha intentat reproduir-lo de forma artificial. L'any 1936, Alan Turing, considerat precursor de la informàtica moderna, va posar la primera pedra formalitzant el concepte d'algorisme, però no és fins l'any 1943 que McCulloch i Pitts van proposar el primer model de neurona formal, que es pot fixar el començament de la teoria de xarxes neuronals artificials (ANN, de l'anglès "Artificial Neural Networks"). La neurona artificial de McCulloch i Pitts imitava, d'una forma molt senzilla, el funcionament d'una neurona biològica, que s'activava donant una senyal de sortida, en funció de les senyals d'entrada.




Fig. 2.1. Esquema d'una neurona artificial. En un símil biològic, les entrades x_n que són ponderades pels pesos w_n , corresponen a les dendrites que reben els estímuls mitjançant la sinapsi, i el cos cel·lular de la neurona correspon a la funció primitiva f que avalua els senyals d'entrada i transmet un senyal de sortida a través de l'axó.

L'any 1957, Frank Rosenblatt, basant-se en la neurona artificial de McCulloch i Pitts va crear la primera xarxa neuronal artificial amb finalitats pràctiques en el món de la computació. La va anomenar perceptró i va ser el primer algorisme que era capaç d'aprendre. El perceptró, que va ser acollit amb gran entusiasme per la comunitat científica, va donar el tret de sortida a la recerca de regles d'aprenentatge que milloressin la capacitat d'aprenentatge de les xarxes. Tot i l'interès inicial generat pel perceptró, ben aviat es va arribar a un punt mort, causat en gran manera per la publicació, l'any 1969, del llibre de Minsky i Papert, en què afirmaven que el perceptró estava destinat únicament a poder resoldre problemes linealment separables. Com a conseqüència d'aquest fet, es van començar a explorar i intentar imitar altres habilitats del cervell humà com és la memòria associativa, capaç de relacionar conceptes basant-se en la seva similitud entre patrons. No va ser fins l'any 1982, quan Hopfield va

unificar uns quants conceptes desenvolupats fins aleshores, que la teoria de ANN no va rebre un nou impuls, i va motivar els treballs de Rumelhart, Hinton i Williams, que van desenvolupar l'algoritme Backpropagation, destinat a entrenar perceptrons multicapa. Des de la dècada dels anys vuitanta, els progressos no s'han aturat i actualment existeix un gran ventall d'ANN que es poden classificar segons l'arquitectura, el paradigma, les regles d'aprenentatge, l'algoritme d'entrenament o el tipus de tasca que han de realitzar.

Arquitectura

A diferència de la disposició tridimensional de les neurones dins el cervell humà, on tenen la capacitat d'interconnectar-se sense restriccions, les neurones artificials s'organitzen en capes que es connecten en sèrie, és a dir, la primera capa es connecta amb la segona, aquesta amb la tercera i així successivament. En aquest cas, la primera capa és la que rep informació de l'exterior (entrada de dades) i l'última capa és la que la transmet a l'exterior (sortida de resultats). El nombre de capes és una variable que no es pot fixar *a priori* i depèn de cada cas concret. Per tant, en el cas d'una xarxa composta únicament per una capa (que rep la informació, la processa i produeix un resultat), parlem de xarxes monocapa, mentre que si està composta per més d'una capa, estem davant d'una xarxa multicapa. En el cas de les xarxes multicapa, podem diferenciar entre les xarxes en què la informació només es transmet de capes anteriors cap a capes posteriors (*feedforward*) i les xarxes que permeten la transmissió d'informació en sentit contrari (*feedback*).

Paradigma

El paradigma o mecanisme d'aprenentatge pot ser de dos tipus: supervisat o no supervisat. En el primer cas, durant l'entrenament o aprenentatge de la xarxa, els pesos de les connexions entre les neurones són ajustats en funció de la desviació entre el valor de sortida real i el desitjat. És a dir, es presenta a la xarxa un conjunt de parelles entrada/sortida amb l'objectiu que sigui capaç d'ajustar les interconnexions neuronals, de forma que per a cada entrada s'obtingui la sortida que li correspon. En el cas del paradigma no supervisat, l'ajust de les interconnexions neuronals es realitza en funció del grau de similitud entre els patrons d'entrada fins a aconseguir que per a dues entrades prou similars s'obtingui una mateixa sortida. Es pot parlar, fins i tot, d'un tercer tipus de paradigma anomenat *híbrid*, que combina l'aprenentatge supervisat i el no supervisat. En aquest cas, tot i que es disposa del valor real de sortida que correspon a cada entrada, només s'indica a la xarxa si la sortida obtinguda és correcta o no. D'aquesta manera, en lloc d'ajustar les interconnexions neuronals en funció de la desviació respecte a la sortida real, es premia únicament les associacions entre entrades i sortides que són correctes mitjançant un aprenentatge per reforçament.

Regles d'aprenentatge

Quan es parla que una ANN és capaç d'aprendre, significa que s'ajusten les intensitats de les diverses interconnexions neuronals (pesos) fins a obtenir un resultat òptim. La manera com s'ajusten aquestes interconnexions depèn de les regles d'aprenentatge. En

termes generals, podem distingir entre quatre tipus de regles. En primer lloc, hi ha la regla de Hebb, que, basant-se en els treballs de Donald Hebb en el camp de la biopsicologia, postula que quan dues neurones s'activen o s'inhibeixen davant un mateix estímul, la intensitat d'interconnexió entre elles augmenta. Aquesta regla s'aplica en mecanismes d'aprenentatge no supervisats. En segon lloc, tenim la regla Delta, que és una evolució de la regla de Hebb i que s'aplica en mecanismes d'aprenentatge supervisats. En aquest cas, els pesos de les interconnexions entre neurones es modifiquen en funció de la diferència entre la sortida real i l'obtinguda per la xarxa. Diferenciem entre la regla Delta de Windrow-Hoff i la regla Delta generalitzada, ja que la primera és només aplicable a xarxes monocapa, mentre que la segona és una adaptació de la primera per a xarxes multicapa. En tercer lloc, hi ha l'aprenentatge competitiu, que, com indica el seu nom, es basa en la competició entre les neurones per guanyar-se el dret a respondre davant un estímul d'entrada. Es tracta d'un mecanisme no supervisat en què únicament els pesos de les interconnexions d'una neurona o un clúster de neurones són reforçats. En últim lloc, trobem l'aprenentatge basat en la màquina de Boltzmann, que empra tècniques probabilístiques per aconseguir un "equilibri tèrmic" dins la xarxa, calculat per a un nivell d'energia E , definit per l'estat de cada neurona, a la qual correspon una temperatura T , segons el nivell d'activació als patrons d'entrada.

Tasca que realitza

Hi ha unes quantes tasques que poden dur a terme les ANN, entre les quals podem destacar la classificació de patrons, l'aproximació de funcions i control, la categorització en classes o la compressió de dades.

Algoritme d'entrenament

Actualment, existeix una gran varietat d'algoritmes d'entrenament que combinen les diverses arquitectures, paradigmes i regles d'entrenament que s'han descrit en aquest apartat. Els tres tipus d'algoritmes d'entrenament que s'han utilitzat en aquest treball, i que es descriuran en profunditat més endavant, són el Backpropagation (BP), el Self Organizing Maps (SOM) i el Fuzzy Adaptive Resonance Theory (Fuzzy ARTMap).

2.2 Backpropagation (BP)

Es tracta d'un algoritme d'aprenentatge supervisat, que utilitza la regla Delta i que en l'àmbit d'aquest treball consta d'una arquitectura multicapa. Rep aquest nom gràcies a la seva característica principal, que és la propagació cap enrere dels errors i és bàsicament un perceptró multicapa.

Té una estructura formada per diverses capes connectades en sèrie que consten d'unes quantes neurones que funcionen en paral·lel, tal com es pot veure a la figura 2.2.




Fig. 2.2. Xarxa multicapa amb estructura 2:3:1. (Capa d'entrada I de dues entrades, capa oculta H amb 3 neurones i capa de sortida O amb 1 neurona)

Cada neurona realitza una suma, ponderada pels pesos, de les entrades que rep i a continuació és avaluada per una funció f .




Fig. 2.3. Descripció detallada del funcionament de cada neurona. En aquest cas, es tracta d'una neurona en una xarxa monocapa. En el cas d'una xarxa multicapa, l'entrada x_1 podria correspondre a la sortida d'una altra capa i la sortida y_1 podria correspondre a l'entrada per a una altra capa.

La funció f s'anomena funció de transferència i pot ser de diferents tipus, com ara tangencial sigmoïdal, logarítmica sigmoïdal o lineal, tot i que les sigmoïdals són les més usades. La característica principal d'aquesta funció, en el cas de xarxes multicapa, és que ha de ser diferenciable per poder dur a terme el càlcul "cap enrere" dels errors.

L'arquitectura de la xarxa, és a dir, el nombre de capes i neurones que contindrà cada capa, no es pot determinar *a priori*, ja que no existeix cap mètode teòric que indiqui quina serà la configuració òptima per a cada situació. Per tant, cal fixar una primera

arquitectura a l'atzar i ajustar-ne la configuració a mesura que se'n comprova el rendiment.

El funcionament de l'algoritme pas a pas és el següent:

1. Se selecciona una arquitectura i el conjunt de dades que s'emprarà per a l'entrenament de la xarxa. En tractar-se d'un aprenentatge supervisat, cal disposar tant de l'entrada com de la sortida real que correspon a cada entrada.
2. S'inicialitzen els pesos (w_{ij}) de les interconnexions neuronals amb valors aleatoris.
3. Es presenta la primera entrada (x_n) a la xarxa i es propaga cap endavant (*feedforward*) calculant la sortida (y_n), seguint el model de la figura 2.3.
4. S'avalua la diferència o error entre la sortida estimada (y_n) i la sortida real (t_n). Normalment, s'usa l'error quadràtic:

$$E = \frac{1}{2} \sum_n (t_n - y_n)^2 \quad (2.1)$$

5. Es propaguen els errors cap enrere (*feedback*), i s'empren els pesos de les interconnexions entre les neurones per avaluar quines connexions són les que més contribueixen a l'error.
6. S'actualitzen els valors dels pesos proporcionalment a la magnitud de l'error i se suma al valor actual el resultat de la següent equació, on η correspon a la velocitat d'aprenentatge.

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} \quad (2.2)$$

7. Es repeteix del pas 3 al 6 per a totes les entrades del conjunt de dades destinades a l'entrenament, fins que l'error de sortida E estigui per sota d'un llindar especificat o s'arribi al màxim nombre d'iteracions fixades.

La resolució de l'equació 2.2 és el cor de l'algoritme Backpropagation i, com a tal, cal que sigui calculada de la forma més eficient possible. Un dels principals problemes de l'algoritme BP és el relacionat amb els mínims locals. La superfície de la funció dels errors sol estar conformada per uns quants pics i valls i durant la resolució és possible caure en un mínim local. Un altre factor important en l'òptima determinació de l'equació 2.2 és la velocitat d'aprenentatge (η), ja que si s'utilitza un valor massa alt l'algoritme esdevé oscil·lant i inestable, mentre que si és massa baix, el temps de computació es torna impracticable. D'entre tots els algoritmes de resolució de l'equació 2.2 existents, s'ha optat per l'algoritme de Levenberg-Marquardt (Hagan i Menhaj,

1994). Aquest algoritme usa una velocitat d'aprenentatge variable, que manté en tot moment l'estabilitat i minimitza el temps de càlcul. L'altre gran avantatge d'aquest algoritme és que està dissenyat per aconseguir una velocitat d'entrenament de segon ordre sense la necessitat de calcular les matrius hessianes en la resolució de les derivades parcials de l'equació 2.2. L'algoritme de Levenberg-Marquardt sembla ser el mètode més ràpid i eficient per entrenar xarxes amb Backpropagation amb MATLAB[®], ja que porta implementada la resolució d'equacions matricials.

Tal com ja s'ha comentat abans, l'arquitectura de la xarxa s'ajusta per assaig i error, de la mateixa manera que es poden provar diferents funcions de transferència i nombre de vegades (*epochs*) que les dades d'entrenament són mostrades a la xarxa durant l'entrenament. Una ANN amb tots els seus paràmetres optimitzats serà capaç de generalitzar les relacions entre els patrons d'entrada i de sortida sense memoritzar-ne cada un. Per tant, un cop entrenada la xarxa, se li presenta un nou conjunt de dades, que no ha estat utilitzat durant l'entrenament, per realitzar-ne la validació. Aquest cop la xarxa només actua en *feedforward* i no s'ajusten els pesos de les interconnexions. Si la diferència global entre les sortides reals i les estimades, o qualsevol altre mètode d'estimació d'error, com pot ésser la correlació entre les dades reals i les estimades, s'adequa als valors desitjats, es pot donar la xarxa com a ben entrenada amb la configuració òptima per a un bon funcionament. En cas contrari, caldrà modificar algun dels seus paràmetres i tornar a començar.

2.3 Self Organizing Maps (SOM)

Desenvolupat per Teuvo Kohonen als anys vuitanta, l'algoritme SOM (Kohonen, 1997) emprava un aprenentatge no supervisat competitiu i una arquitectura multicapa. Es tracta d'un algoritme que intenta reproduir la capacitat del cervell humà de reconèixer patrons en funció de l'activació d'una part concreta del cervell segons l'estímul rebut (visual, auditiu...). La principal característica de SOM és que és capaç de projectar dades de dimensions elevades a un espai bidimensional tot preservant la topologia de l'espai de les dades.

La xarxa SOM està composta per dues capes seguint l'esquema de la figura 2.4. La capa d'entrada té tantes neurones com dimensions tenen els patrons d'entrada, mentre que la segona capa, que es pot considerar la capa de sortida, té un nombre de neurones en funció del nombre de patrons que s'emprin per a l'entrenament de la xarxa. Cada neurona de la capa d'entrada es connecta en *feedforward* amb cada neurona de la segona capa i el grau d'interconnexió es fixa mitjançant els pesos (w_{ij}). Durant l'entrenament, cada patró d'entrada és descompost en les seves n dimensions i s'avalua la seva similitud amb les neurones de la segona capa. En tractar-se d'un algoritme amb regla d'aprenentatge competitiva, només una neurona resulta guanyadora ("winner take all") i, com a conseqüència d'això, els pesos de les interconnexions amb aquesta neurona són modificats, de manera que es reforça la similitud entre el patró d'entrada i aquesta neurona. D'altra banda, en preservar-se la topologia de l'espai en la projecció

bidimensional, les neurones adjacents a la neurona guanyadora també presenten un cert grau de similitud amb el patró d'entrada i , per tant, els seus pesos també són reforçats.

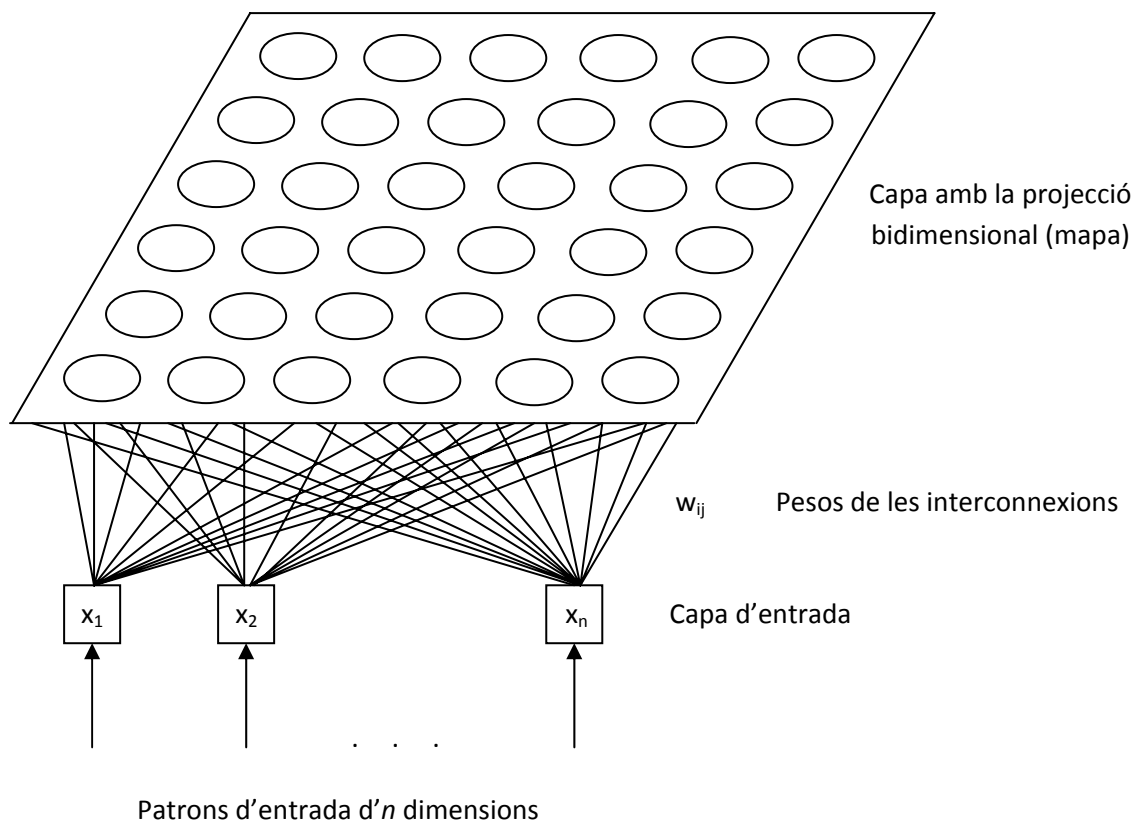


Fig. 2.4. Esquema d'una xarxa SOM de dimensions 6×6 amb n entrades.

A continuació, es descriu de forma detallada el funcionament de l'algoritme:

1. Se seleccionen les dimensions de la segona capa (mapa) de la xarxa en funció de la quantitat de dades que s'utilitzaran durant l'entrenament. Un mapa massa petit farà que els patrons no tinguin prou llibertat per classificar-se correctament, mentre que un mapa massa gran requerirà un temps de càlcul molt elevat.
2. S'inicialitzen els pesos (w_{ij}) de les interconnexions neuronals amb valors aleatoris del 0 a l'1. Com que les dades d'entrada es normalitzen entre $[0,1]$, es pot considerar que els valors aleatoris pertanyen al subespai de les dades destinades a l'entrenament. D'aquesta manera es requereixen menys iteracions fins a aconseguir un entrenament correcte.
3. Es presenta la primera entrada $x = [x_1, x_2, \dots, x_n]$ i es busca quina neurona m_i de la segona capa amb pesos $[w_{i1}, w_{i2}, \dots, w_{in}]$ s'hi assembla més (BMU, de l'anglès "Best Matching Unit"). Generalment s'usa la distància euclidiana per

determinar la “similitud”. Per tant, es busca quina neurona de la segona capa és més pròxima al patró d’entrada.

$$\|x - m_{BMU}\| = \min_i \{\|x - m_i\|\} = \min_i \left\{ \sqrt{\sum_{j=1}^n (x_j - w_j^i)^2} \right\} \quad (2.3)$$

- Es modifiquen els pesos de la neurona guanyadora (m_{BMU}) i del veïnatge.

$$m_i(t + 1) = m_i(t) + h_{BMU,i}[x(t) - m_i(t)] \quad (2.4)$$

La funció h , anomenada *funció de veïnatge*, es compon de dues parts: la primera, $\alpha(t)$, és la velocitat d’aprenentatge, que presenta un valor entre 0 i 1 i que decreix amb les iteracions de l’algorisme. La segona part és la que dona nom a la funció i , per tant, fa referència al veïnatge. La seva funció és determinar quin conjunt de neurones al voltant de la guanyadora es considera veí i , per tant, els seus pesos també seran modificats. Existeixen unes quantes possibilitats per determinar el veïnatge, tant amb un radi constant al voltant de la neurona guanyadora com amb un de variable, però la més usada és una funció gaussiana, en la qual el radi de veïnatge (σ) decreix amb les iteracions de l’algorisme.

$$h_{BMU,i} = \alpha(t) \exp\left(-\frac{\|r_i - r_{BMU}\|^2}{2\sigma^2(t)}\right) \quad (2.5)$$

on r_i i r_{BMU} corresponen a la posició vectorial dins la graella del mapa. La graella sol ser quadrada o hexagonal. Com es pot veure a la figura 2.5, una graella quadrada comporta tenir 8 veïns directes, mentre que per a la graella hexagonal es tenen 6 veïns. En aquest treball, en tot moment es treballa amb graelles hexagonals, ja que la distància entre els 6 veïns és la mateixa, a diferència de la graella quadrada, fet que dona més estabilitat a l’algorisme.




Fig. 2.5. Graella per a mapa (segona capa de neurones) SOM de tipus a) quadrada i b) hexagonal.

- Es repeteixen els passos 4 i 5 fins que els canvis en els pesos del pas 4 siguin inferiors a un llindar especificat o s’arribi al màxim nombre d’iteracions fixades.

L'entrenament de la xarxa se sol dividir en dues parts. La primera, més tosca, amb radis de veïnatge inicials més elevats i de curta durada (amb poques repeticions o *epochs* del set de dades d'entrenament). La segona part, anomenada *fin*, treballa amb un radi de veïnatge baix i constant i repeticions o *epochs* més elevades.

Per determinar la qualitat de l'entrenament realitzat, existeix una sèrie de mesures que avaluen la resolució del mapa creat o la conservació de la topologia original de les dades. En aquest treball, s'han utilitzat l'error de qualitat (q_e) i l'error topogràfic (t_e) proposat per Kiviluoto (1996) per determinar la resolució del mapa i la conservació de la topologia, respectivament:

$$q_e = \frac{1}{N} \sum_{i=1}^N \|x_i - m_{BMU,i}\| \quad (2.6)$$

on N correspon al nombre total de patrons (x) usats en l'entrenament. Amb aquesta fórmula es calcula la distància mitjana entre cada patró d'entrada i la neurona guanyadora (BMU) corresponent.

L'error topogràfic (q_t) calcula la proporció de vectors d'entrada en els quals les dues neurones més similars a ell no són veïnes directes.

$$q_t = \frac{1}{N} \sum_{i=1}^N u(x_i) \quad (2.7)$$

on $u(x_i) = 1$ si la neurona guanyadora (BMU) i la segona més similar (segon BMU) per a cada patró d'entrada (x) no són neurones adjacents. En cas contrari, $u(x_i) = 0$.

Una de les principals qualitats de SOM és la representació visual dels resultats. Un cop la xarxa s'ha entrenat, és possible observar la classificació dels patrons d'entrada en zones o clústers.

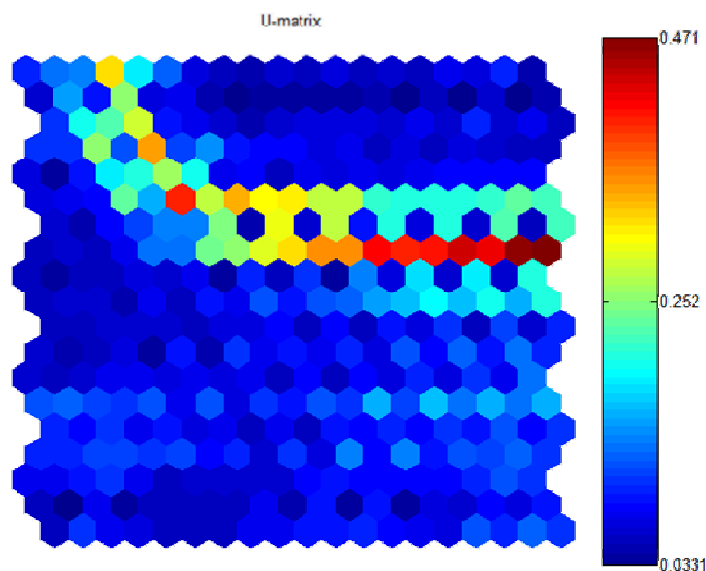


Fig. 2.6. Exemple d'una U-matrix on es poden distingir clarament dues zones o clústers separades per distàncies elevades entre neurones.

Mitjançant la representació de la matriu de distàncies unificades (U-matrix, figura 2.6), que mostra la distància entre neurones, és possible observar, d'una banda, zones on les distàncies són baixes i que corresponen a un conjunt o clúster de neurones amb característiques similars i, d'altra banda, zones on les distàncies són grans i, per tant, corresponen a límits de separació entre clústers.

Tot i així, molts cops la U-matrix no és suficient per visualitzar la creació de clústers de patrons i és necessari recórrer a algorismes de clusterització com el K-means (Hartigan i Wong, 1979). Aquest algorisme agrupa els pesos de cada neurona (m_i) en un nombre, fixat *a priori*, de clústers, i minimitza la distància euclidiana entre el centroide (centre de cada clúster) i les neurones assignades a aquest clúster. El funcionament pas a pas de l'algorisme K-means és el següent:

1. S'escull un nombre de clúster i s'inicialitza el vector de cada centroide que tindrà les mateixes dimensions que el vector (pesos w) de les neurones del mapa SOM entrenat *a priori*.
2. Es determina quines neurones pertanyen a cada clúster en funció de la distància euclidiana entre el centroide i les neurones de cada clúster.
3. Es modifica el vector de cada centroide de forma que es minimitzi la distància mitjana entre el centroide i les neurones que se li han assignat en el pas anterior.
4. Es repeteixen els passos 3 i 4 fins que la modificació dels vectors de cada centroide és inferior a un valor llindar especificat.

Un cop realitzada la clusterització, ja es pot dur a terme una representació gràfica del clúster al qual li correspon cada patró d'entrada del mapa SOM. A cada patró d'entrada li correspon una neurona del mapa SOM (BMU) i a aquesta neurona, al seu temps, un dels clústers creats amb K-means; per tant, amb aquesta relació, s'obté la correspondència entre patrons d'entrada i clústers.

En el cas que *a priori* no es conegui el nombre òptim de clústers amb què s'han d'organitzar els patrons d'entrada, cal provar diferents valors i utilitzar algun mètode per avaluar-ne el valor òptim. D'entre els diferents mètodes existents, s'ha escollit l'índex de Davies-Bouldin (Davies i Bouldin, 1979), que calcula la ràtio entre el grau de compactació dins de cada clúster i la distància entre clústers:

$$DB = \frac{1}{c} \sum_{i=1}^c \max_{i \neq j} \left\{ \frac{\Delta(X_i) + \Delta(X_j)}{\delta(X_i, X_j)} \right\} \quad (2.8)$$

on, c és el nombre de clústers, $\Delta(X_i)$ és la distància entre membres dins del clúster i $\delta(X_i, X_j)$ és la distància entre diferents clústers. Com més baixos siguin els valors de DB, més bona clusterització es fa.

Una altra ajuda visual de SOM és l'estudi de similitud mitjançant Principal Component Analysis (PCA). Un cop entrenada una xarxa, es poden representar mapes per a cada dimensió dels vectors o pesos corresponents a cada neurona, respectant-ne la situació en l'espai bidimensional. Utilitzant un codi de colors per a tot el rang de valors que cobreixen aquests vectors, és possible observar similituds entre les dimensions dels patrons d'entrada i, donat el cas, reduir-ne la dimensió si dues o més de les dimensions són linealment dependents i, per tant, redundants. En l'exemple següent, es mostra la representació dels vectors SOM per a les quatre dimensions de què es compon un conjunt de patrons utilitzats en l'entrenament d'una xarxa SOM. Es pot observar com dues de les representacions són molt similars i, per tant, gairebé linealment dependents.




Fig. 2.7. Exemple d'una representació de les quatre dimensions dels vectors SOM d'una mapa de dimensions 10×10 destinat a un Principal Component Analysis.

2.4 Fuzzy Adaptive Resonance Theory (Fuzzy ARTMap)

Aquest algoritme d'entrenament és fruit de l'evolució de la Teoria de la Ressonància Adaptativa (ART, de l'anglès "Adaptive Resonance Theory"), desenvolupada per Carpenter i Grossberg (1998). La teoria busca conciliar el dilema de la plasticitat envers l'estabilitat. La plasticitat és la capacitat d'una xarxa d'aprendre nous patrons, mentre que l'estabilitat és la capacitat de no oblidar el que ha après. Quan s'entrena una xarxa amb algoritmes tradicionals, com Backpropagation, la xarxa s'adapta per reconèixer el conjunt de patrons utilitzats durant l'entrenament. Tot i que s'intenta que el conjunt de patrons de l'entrenament cobreixi tot el domini del problema que es vol resoldre, en alguns casos cal afegir *a posteriori* algun patró nou. Quan es dona aquest cas, no és

possible entrenar un altre cop la xarxa amb els nous patrons, ja que hi ha el perill que oblidí part dels apresos anteriorment i cal començar de nou, i entrenar la xarxa amb el conjunt complet de patrons (els vells i els nous). Per tant, ART presenta una solució a aquest problema, ja que dissenya un nou algoritme que permet que la xarxa aprengui nous patrons sense oblidar els vells. Començant per l'algoritme ART1, que només acceptava patrons binaris i a través de diverses millores, es va arribar a Fuzzy ARTMap (Carpenter i Grossberg, 1998). El nom de l'algoritme es compon de tres parts, que indiquen la seva evolució tècnica. En primer lloc, el terme Fuzzy indica que utilitza la lògica difusa, fet que permet una generalització millor en la classificació dels patrons d'entrada. En segon lloc, el terme ART, del qual ja s'ha descrit el significat, i finalment, el terme Map, que fa referència a la unió de dos mòduls ART, i converteix el paradigma de la xarxa de no supervisat (en el cas d'ART) a supervisat, ja que un mòdul serveix per a la classificació de les entrades mentre l'altre es destina a la classificació de les sortides. La figura 2.8 mostra un esquema de l'estructura d'una xarxa Fuzzy ARTMap.

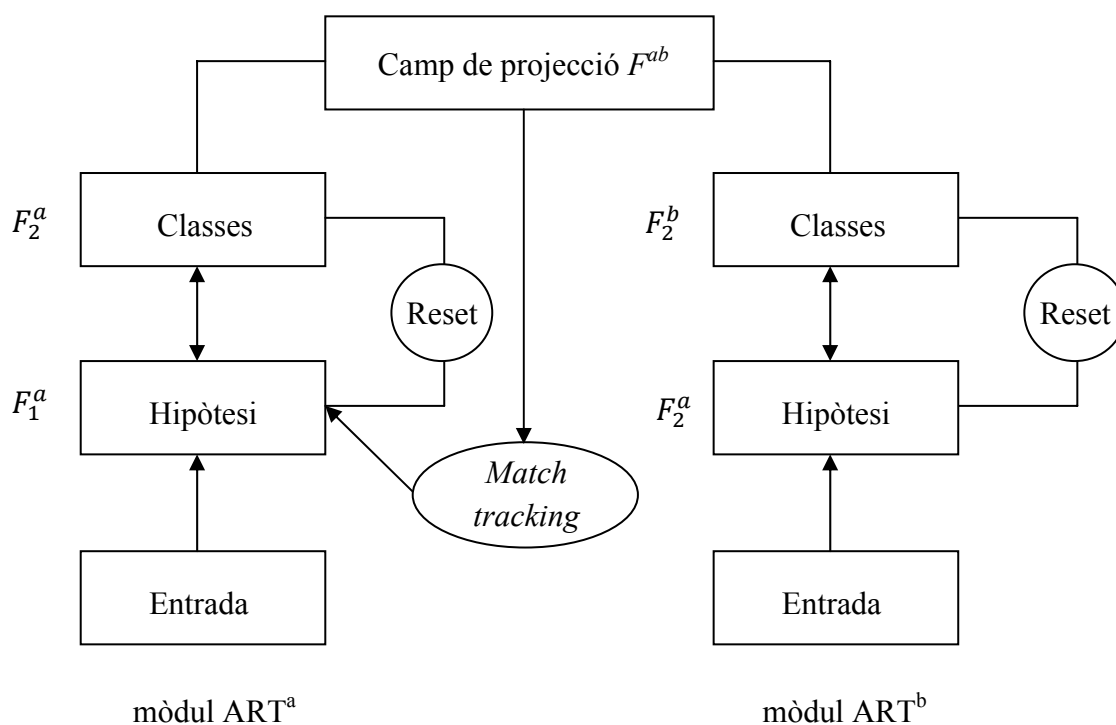


Fig. 2.8. Esquema de l'arquitectura d'una xarxa Fuzzy ARTMap.

Parlem, doncs, d'una xarxa multicapa, amb aprenentatge supervisat i de regla competitiva. Per realitzar l'entrenament de la xarxa, s'introdueixen l'entrada i la sortida en els dos mòduls que formen la xarxa (ART^a i ART^b, respectivament). Les entrades es van agrupant en diferents classes o categories (F_2^a) en funció de la similitud entre elles. Cada categoria del mòdul ART^a està lligada a una categoria del mòdul ART^b, que correspon al valor de sortida mitjançant el camp de projecció (F^{ab}). Quan s'introdueix

una nova entrada, aquesta entra en “ressonància” amb una categoria del mòdul ART^a; al mateix temps, una categoria del mòdul ART^b entra en “ressonància” amb la sortida corresponent. A continuació, es comprova que les dues categories ja estiguessin relacionades i s’ajusten els pesos d’aquestes categories perquè reconeguin aquest nou patró. En cas que cap categoria d’ART^a o ART^b entri en “ressonància”, es crea una nova categoria, ja que això significa que la nova entrada és un patró completament nou i diferent de la resta. El fet de modificar únicament les categories que entren en “ressonància” i no tocar la resta és el que permet solucionar el dilema de l’estabilitat-plasticitat de l’aprenentatge. Això permet que, si un cop finalitzat l’entrenament es vol afegir un nou patró, no calgui que es repeteixi tot l’entrenament anterior afegint-hi el nou patró, perquè la xarxa només modificarà la categoria que entri en “ressonància” o en crearà una de nova.

A continuació, es descriu de forma més detallada el funcionament de l’algoritme:

1. S’inicialitzen els pesos (w) de les connexions entre F_1 i F_2 . En aquest cas, no cal fixar *a priori* un nombre de neurones, ja que es van creant a mesura que són necessàries. S’inicialitza la resta de paràmetres com són α , β o ρ , entre d’altres, que es descriuen més endavant.
2. S’introdueix la primera parella d’entrada i sortida i es preprocessen normalitzant les dades entre 0 i 1 i creant un codi complement. Per tant, si un patró d’entrada té M dimensions, un cop preprocessat, tindrà $2M$ dimensions.
3. Per a cada mòdul ART (ART^a per al patró d’entrada i ART^b per a la corresponent sortida), es calcula l’activitat (T) de les neurones d’ F_2 per al patró d’entrada I a través dels pesos (w):

$$T_j(I) = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (2.9)$$

on $\alpha > 0$ i tindrà el valor més baix possible; prevaldran les classes amb norma més alta. L’operador difús o *fuzzy* (\wedge) es defineix com:

$$(p \wedge q) = \min(p_i, q_i) \quad (2.10)$$

i la norma $|\cdot|$ com:

$$|p| = \sum_{i=0}^M |p_i| \quad (2.11)$$

4. Es determina la neurona d’ F_2 amb l’activitat més alta.

$$T_j = \max \{T_j : j = 1, \dots, N\} \quad (2.12)$$

5. La neurona d' F_2 amb màxima activitat (T_j) és l'escollida com a representant del patró I , i el seu valor és enviat a F_1 a través dels pesos (w). Allí s'hi determina el grau de similitud amb el patró d'entrada, i es decideix així si la neurona guanyadora d' F_2 (categoria) es mereix representar el patró d'entrada I .

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (2.13)$$

on ρ té valors entre 0 i 1 i determina la finor de la classificació. Com més alt és el valor de ρ , més exigent és la classificació i es creen més categories. Si la condició es compleix, es diu que el patró I entra en ressonància amb la categoria assignada (T_j). En cas que no es compleixi, es desactiva la neurona guanyadora i es torna al pas 4, i es calcula una nova T_j . Si cap neurona d' F_2 no supera la condició de ressonància, es crea una nova categoria (neurona) a F_2 .

6. Un cop hi ha ressonància tant per a ART^a com per a ART^b, s'actualitza la memòria associativa F^{ab} (camp de projecció). Es poden donar el casos següents:
- És el primer cop que la neurona d' F_2^a entra en ressonància. S'actualitza F^{ab} de forma que es relacioni la neurona d' F_2^a amb la d' F_2^b .
 - Les neurones d' F_2^a i F_2^b ja estaven relacionades. No s'actualitza F^{ab} .
 - La neurona F_2^a ja està relacionada, però no concorda amb F_2^b . En aquest cas, entra en funcionament el *match tracking*, es torna al pas 3 per al mòdul ART^a i s'augmenta temporalment el valor de ρ . D'aquesta manera, l'entrada del patró I s'anirà assignant a altres classes fins que es doni el cas 6a o 6b.
7. Es modifiquen els pesos (w) de les neurones guanyadores.

$$w_j^{(nou)} = \beta(I \wedge w_j^{(vell)}) + (1 - \beta)w_j^{(vell)} \quad (2.14)$$

on β és la taxa d'aprenentatge i té valors entre 0 i 1. Com més alts siguin els valors, es produeix un aprenentatge més ràpid, mentre que amb valors baixos és més estable.

L'entrenament de la xarxa es dona per finalitzat quan s'han presentat tots els patrons. Per validar-la, es desactiva el mòdul ART^b, de manera que quan es presenta una entrada a ART^a, s'activa una sortida mitjançant el camp de projecció (F^{ab}) i es comprova que correspongui a la sortida real. De la mateixa manera es poden realitzar tant tasques de classificació com de predicció. I en cas que es vulgui afegir nous patrons d'entrenament, només cal tornar a activar el mòdul ART^b.

2.5 Referències

CARPENTER G.; S. GROSSBERG (1998). "The ART of adaptive pattern recognition by a self-organizing neural network", *Computer* 21(3), 77-88.

CARPENTER, G. A.; S. GROSSBERG; N. MARKUZON; J. H. REYNOLDS; D. B. ROSEN (1992). "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps", *IEEE Transactions on Neural Networks* 3, 698-713.

DAVIES, D. L.; D. W. BOULDIN (1979). "A cluster separation measure", *IEEE Transactions on Pattern Analysis and Machine Learning* 1(2).

HAGAN, M. T.; M. MENHAJ (1994). "Training feed-forward networks with the Marquardt algorithm", *IEEE Transactions on Neural Networks* 5(6), 989-993.

HARTIGAN, J. A.; M. A. WONG (1979). "A K-means clustering algorithm", *Applied Statistics* 28(1), 100-108.

KIVILUOTO, K. (1996). "Topology preservation in Self-Organizing Maps", *Proceedings of International Conference on Neural Networks (ICNN)*, 294-299.

KOHONEN, T. (1997). "Self-organizing maps". *Series in Information Sciences* 30. Heidelberg: Springer.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Capítol 3. Resultats

Els resultats obtinguts durant la realització d'aquesta tesi es poden dividir en tres subcapítols. Cada subcapítol és una ampliació detallada dels tres articles científics que s'han elaborat a partir de la recerca realitzada i que es poden trobar a l'annex.

Subcapítol A

Títol: Simulació de sèries temporals de coeficients de pressió sobre un cilindre en condicions altament turbulentes.

Xarxes neuronals artificials emprades: Fuzzy ARTMap.

Aplicació pràctica: Generar sèries temporals de coeficients de pressió a partir de dades històriques del sistema.

Publicació: GAVALDÀ, X.; J. FERRER-GENER; G. A. KOPP; F. GIRALT; J. GALSWORTHY (2009). "Simulating pressure coefficients on a circular cylinder at $Re = 10^6$ by cognitive classifiers", *Computers and Structures* 87, 834-846.

Subcapítol B

Títol: Classificació i reconstrucció de series temporals de coeficients de pressió sobre un cilindre en condicions altament turbulentes.

Xarxes neuronals artificials emprades: Self Organizing Maps i K-means.

Aplicació pràctica: Classificació de sèries temporals de coeficients de pressió a partir dels seus moments estadístics i reconstrucció de sèries temporals de coeficients de pressió a partir de la seva mitjana, desviació estàndard i una sèrie temporal de referència.

Publicació: GAVALDÀ, X.; J. FERRER-GENER; G. A. KOPP; F. GIRALT. "Classification and generation of pressure coefficients on a circular cylinder at $Re = 10^6$ using artificial neural networks". [Pendent d'enviar.]

Subcapítol C

Títol: Interpolació de coeficients de pressió sobre teulades de cases prefabricades de baixa alçada.

Xarxes neuronals artificials emprades: Self Organizing Maps i Backpropagation.

Aplicació pràctica: Creació d'un model d'interpolació de la base de dades, de coeficients de pressió sobre teulades de cases prefabricades de baixa alçada, del United States National Institute of Standards and Technology (NIST).

Publicació: GAVALDÀ, X.; J. FERRER-GENER; G. A. KOPP; F. GIRALT. "Interpolation of pressure coefficients for low-rise building of different plan dimensions and roof slopes using artificial neural networks", *J. Wind Eng. Ind. Aerodyn.* [Pendent d'acceptació.]

Capítol 3A. Simulació de sèries temporals de coeficients de pressió sobre un cilindre en condicions altament turbulentes

3A.1 Introducció

L'objectiu d'aquesta primera part del treball és la d'assentar les bases per al model d'interpolació de la base de dades del United States National Institute of Standards and Technology (NIST). Es demostrarà que les dades de pressió al voltant d'un cos són suficients per capturar la dinàmica d'un sistema mitjançant l'ús de xarxes neuronals artificials (ANN).

Es parteix, com a base, del treball realitzat per Giralt et al. (2000), on van predir satisfactòriament camps instantanis de velocitat en diverses localitzacions de forma simultània dins l'estela, completament desenvolupada, creada per un cilindre aigües amunt en condicions de $Re = 1200$, utilitzant ANN del tipus Fuzzy ARTMap (FAM).

El sistema dinàmic que s'estudia està compost per un cilindre circular sotmès a condicions de vent altament turbulentes ($Re = 1,0 \times 10^6$). En aquestes condicions, tot i la simplicitat geomètrica del cilindre, el flux al seu voltant presenta una gran complexitat a causa de la turbulència del corrent lliure, el desprendiment de la capa límit i la formació de vòrtexs aigües avall. A partir de mesures experimentals de pressió sobre la seva superfície, es vol simular la dinàmica del sistema emprant ANN del tipus Fuzzy ARTMap (FAM).

Unes quantes FAM, treballant en paral·lel, s'encarregaran de predir els valors instantanis de pressió sobre el cilindre en diversos punts, emprant únicament valors de pressió anteriors del punt mateix o d'altres punts. Per tant, les ANN actuaran com una caixa negra, que, capturant la dinàmica del sistema durant el seu entrenament, seran capaces de generar sèries temporals de pressió sobre la superfície d'un cilindre immers en un fluid en condicions altament turbulentes.

El treball es divideix en tres etapes ben diferenciades:

1. Anàlisi de la complexitat de les dades experimentals que es volen predir. Es comprovarà que el sistema que es vol simular presenta una gran complexitat, equivalent al del futur treball amb la base de dades del NIST.
2. Caracterització de les FAM que s'utilitzaran. La clau del disseny d'aquestes xarxes està en la selecció de la combinació de patrons d'entrada que continguin la informació suficient perquè puguin capturar la dinàmica del sistema.
3. Avaluació dels resultats obtinguts. Es demostrarà que amb una òptima selecció de les dades de pressió, les ANN són capaces de crear models de predicció basats únicament en dades de pressió.

3A.2 Dades experimentals

Les dades experimentals utilitzades en aquest treball provenen d'un túnel de vent tipus jet d'1 MW de potència situat a la universitat Monash d'Austràlia. Un cilindre rígid, de 50 cm de diàmetre, és instrumentat amb 32 sensors de pressió situats sobre la superfície, seguint el perímetre de la circumferència situada al centre del cilindre, tal com es veu a la figura 3A.1, i que correspon, al mateix temps, al centre de l'amplada del túnel de vent.

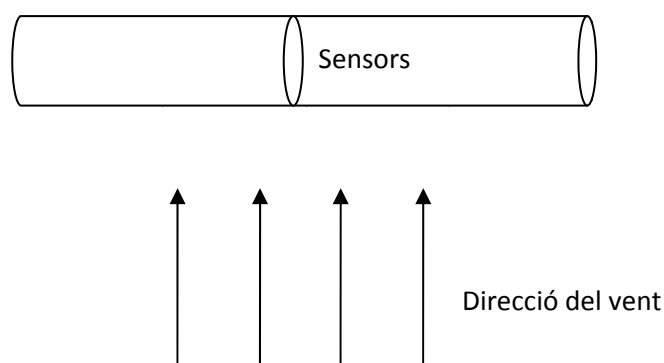


Fig. 3A.1. Esquema del cilindre.




Fig. 3A.2. Distribució dels sensors al voltant del cilindre.

Pel que fa a l'alçada, el cilindre està situat a 2,23 m respecte a la superfície del túnel de vent, que té una alçada màxima de 5 m. Aquesta col·locació no correspon a l'alçada mitjana ideal, fet que provoca una asimetria entre el flux d'aire per sobre i per sota del cilindre, tal com es veurà més endavant en l'anàlisi de les dades experimentals. Els 32 sensors de pressió prenen 200 mostres per segon durant 1 minut i estan situats uniformement cada $11,25^\circ$ al voltant del cilindre. Van numerats, començant pel punt on incideix el vent i que correspon a l'angle 0° . A la figura 3A.2 es mostra amb detall la numeració i situació dels 32 sensors.

La velocitat del vent, mesurada al corrent lliure, és de 30 m/s, per la qual cosa el nombre de Reynolds (Re), basat en el diàmetre del cilindre, és d' $1,0 \times 10^6$. El corrent lliure és clarament turbulent, amb una intensitat de turbulència del 5% i una escala integral $L_u \approx 14$ cm ($L_u/D = 0,28$). Una informació més detallada sobre les dades experimentals es pot trobar a la tesi de Galsworthy (2000).

3A.3 Anàlisi de les dades experimentals

Per poder avaluar la complexitat de les dades que es volen simular amb les xarxes Fuzzy ARTMap, cal conèixer bé el comportament dels perfils de pressió al voltant del cilindre. En primer lloc, cal dir que en tot moment es treballa amb coeficients de pressió (C_p), que són una mesura adimensional de la pressió sobre la superfície del cilindre:

$$C_p = \frac{p - p_\infty}{\frac{1}{2} \rho_\infty V_\infty^2} \quad (3A.1)$$

on p és la pressió en el punt on s'avalua C_p , p_∞ és la pressió al corrent lliure (on el corrent és uniforme i amb nivells baixos de turbulència), ρ_∞ és la densitat de l'aire i V_∞ és la velocitat al corrent lliure de l'aire. Normalment, quan es treballa amb models a escala, s'empren els coeficients de pressió en lloc de les pressions, ja que els coeficients de pressió són independents de les dimensions del model.

Zdravkovich (1997) va caracteritzar el flux d'un fluid al voltant d'un cilindre circular en quatre zones diferenciades (figura 3A.3). Aquestes zones són:

- i)* Punt d'estancament. Primer punt on incideix el flux i on la velocitat local és nul·la. La pressió és màxima en aquest punt i el valor del coeficient de pressió és igual a 1.
- ii)* Capa límit. Es crea una fina capa entre la superfície del cilindre i el corrent lliure. La velocitat del fluid és inferior a la del corrent lliure i, per tant, tindrà valors de C_p negatius.
- iii)* Flux irrotacional pertorbat. El corrent lliure es veu afectat per la presència del cilindre i en vorejar-lo augmenta de velocitat.

iv) Estela. Comença a partir dels punts de separació (un a la cara superior del cilindre i un a la inferior). Aigües avall del punt de separació la diferència de pressió entre la zona *iii* i la *iv*, fa que aquesta última tiri enrere, i provoqui la separació de la capa límit i el desprendiment de vòrtexs.





Fig. 3A.3. Flux al voltant d'un cilindre circular submergit en un fluid (Zdravkovich, 1997).

La situació dels punts de separació que fixen el principi de la zona *iv* varia segons el nombre de Reynolds. Segons Basu (1982), per a valors de Reynolds (Re) posterítics, el punt de separació a la cara superior se situa entre els 100° i 110° . Més difícil és fixar quan es pot considerar que un valor de Reynolds és posterític. Zdravkovich (1997) suggereix mínims entre $3,5 \times 10^6$ i 6×10^6 . En el nostre cas, no s'arriba a aquests valors, però cal tenir en compte que el flux al túnel de vent presenta una intensitat de turbulència al corrent lliure del 5%, fet que a la pràctica és com si el valor de Re fos més gran, ja que les fluctuacions provocades per la intensitat de turbulència desplacen els punts de separació en direcció aigües avall.

A la figura següent, s'hi mostren els valors de la mitjana (\bar{C}_p) i la desviació estàndard (\tilde{C}_p) dels coeficients de pressió per als 32 sensors.






Fig. 3A.4. Valors experimentals de la a) mitjana i la b) desviació estàndard dels coeficients de pressió per a cada sensor sobre la superfície del cilindre.

Observant la figura 3A.4, el que primer es veu és la asimetria en les dues figures. Com ja s’ha comentat a la secció anterior, la asimetria (entre la part superior del cilindre, $0^\circ - 180^\circ$, i la inferior, $180^\circ - 360^\circ$) es deu al fet que el cilindre no estava situat a l’alçada idònia dins el túnel de vent. Tot i que a la pràctica la asimetria hauria d’evitar-se sempre que fos possible, per a aquest treball suposa un repte afegit a l’hora d’intentar simular el comportament temporal de les pressions. A la figura 3A.4a, s’hi pot veure com el punt d’estancament està situat a l’angle 0° amb un valor de $\bar{C}_p = 1$. A la figura 3A.4b, s’hi observa com les majors fluctuacions temporals (desviació estàndard) dels valors de C_p se situen al voltant dels punts de separació, és a dir, entre els $90^\circ - 120^\circ$ a la part superior i els $240^\circ - 270^\circ$ a la part inferior. Un altre punt important que cal tenir en compte és el desprendiment de vòrtexs a l’estela del cilindre (zona iv de la figura 3A.3). Per a valors de Reynolds molt elevats, com és aquest cas, el desprendiment es realitza de forma “organitzada”; es desprenen, de manera alterna, vòrtexs de la part superior i inferior del cilindre, i es crea l’anomenat carrer de vòrtexs de Von Kármán. Els vòrtexs afecten el balanç de forces sobre el cilindre i la seva periodicitat pot ser calculada a través de la desviació estàndard en les dades temporals del coeficient de sustentació (C_s) del cilindre.

$$C_s(t) = \sum_{i=1}^{32} \frac{\pi}{32} \cdot C_p(\theta, t) \cdot \sin \theta \quad (3A.2)$$

A la figura 3A.5, s’hi mostra l’autoespectre de la desviació estàndard del coeficient de sustentació. Es pot observar com presenta un pic ben definit al voltant dels 11 Hz.




Fig. 3A.5. Densitat espectral de potència de la desviació estàndard del coeficient de sustentació vs la freqüència de la presa de mesures experimentals.

A la figura 3A.6, s'hi mostra la sèrie temporal de coeficients de pressió en l'interval de temps 4-6 s per al sensor situat en el punt d'estancament (0°) i el sensor situat a la zona on hi ha el punt de separació de la capa límit a la part superior del cilindre (101°).

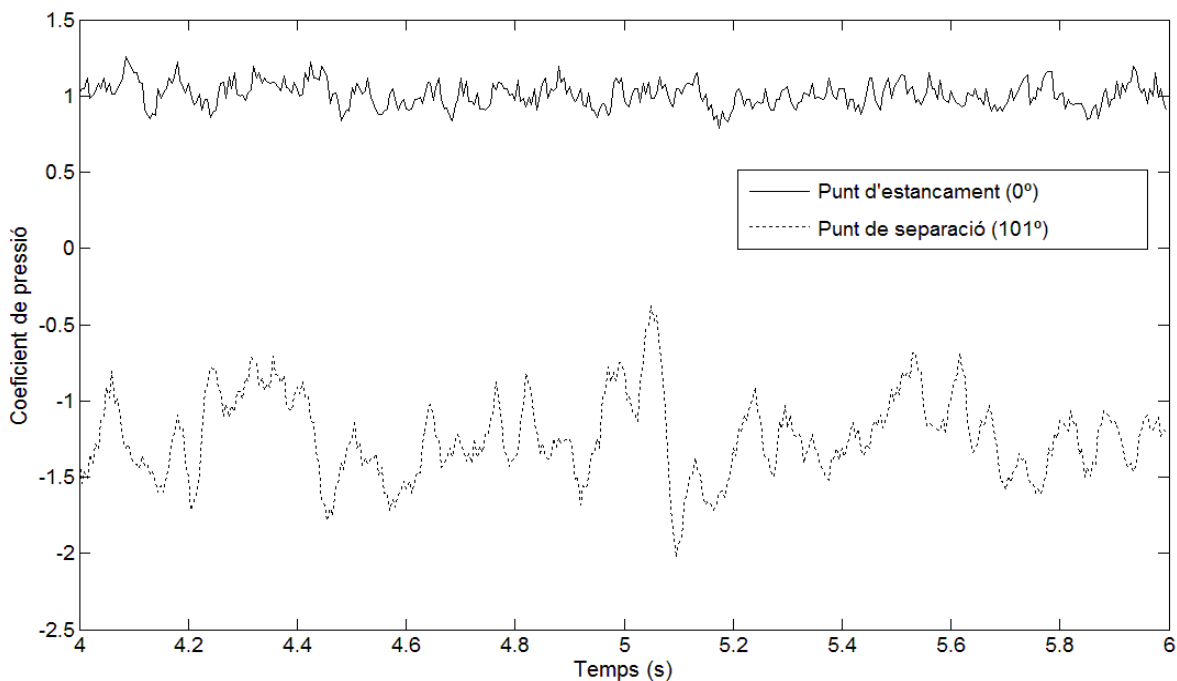


Fig. 3A.6. Valors experimentals del coeficient de pressió per als sensors situats als angles 0° i 101° .

Hom pot veure com la freqüència de les fluctuacions de C_p és més gran en el punt d'estancament que en el punt de separació. En el cas del punt de separació, la freqüència està governada per la freqüència de desprendiment dels vòrtexs, és a dir, cada 0,09 s, aprox. Pel que fa al punt d'estancament, hauria d'estar governada per la turbulència del corrent lliure. Una forma de calcular-la de manera aproximada és mitjançant la funció d'autocorrelació φ :

$$\varphi = \frac{\overline{C_{pi}' C_{pj}'}}{\overline{C_p'^2}} \quad (3A.3a)$$

on C_{pi}' és la fluctuació del coeficient de pressió ($C_p - \bar{C}_p$) a l' instant de temps t i C_{pj}' és la fluctuació a l' instant de temps $t + \tau$, on τ és el temps de desfasament.




Fig. 3A.7. Autocorrelació de les dades experimentals per al sensor situat al punt d'estancament (0°).

Observant la figura 3A.7, es pot veure que, a partir d'un desfasament de 0,025 s, l'autocorrelació de les dades experimentals del coeficient de pressió, per al sensor situat al punt d'estancament, és negativa. Aquest desfasament es correspon aproximadament a la freqüència de les fluctuacions que s'observa a la figura 3A.6 per al punt d'estancament.

Per tant, es pot veure com, dependent de la zona sobre el cilindre, el comportament de les sèries temporals dels coeficients de pressió és molt diferent. Per acabar l'anàlisi de les dades experimentals, es mostren les correlacions espacials dels sensors pròxims al punt d'estancament, al punt de separació de la part superior del cilindre i del sensor situat a 180°. La correlació espacial es calcula de forma anàloga a l'autocorrelació (equació 3A.3a).

$$\varphi = \frac{\overline{C'_{pi}C'_{pj}}}{\overline{C'_{pi}}\overline{C'_{pj}}} \quad (3A.3b)$$

on aquest cop el subíndex j fa referència a les dades d'un altre sensor en lloc del mateix sensor amb les dades desfasades temporalment.




Fig. 3A.8. Correlació espacial de tres sensors (situats a les posicions 0°, 101° i 180°) amb la resta de sensors situats sobre la superfície d'un cilindre circular.

El coeficient de correlació per al sensor situat al punt d'estancament (0°) disminueix ràpidament a mesura que ens allunyem en ambdues direccions. Això indica que la zona influïda únicament per la turbulència del corrent lliure és molt reduïda. En canvi, el sensor situat a la zona de separació (101°) presenta coeficients de correlació moderats en un ampli rang en ambdues direccions, especialment aigües avall, on la influència de la freqüència del desprendiment de vòrtexs predomina. En canvi, la correlació d'aquest sensor amb els situats a la part inferior del cilindre ($\theta > 180^\circ$) és negativa. Això es deu al fet que el desprendiment dels vòrtexs de la part superior del cilindre va desfasat respecte al desprendiment de la part inferior, tal com s'ha comentat anteriorment fent referència als camins de vòrtexs de Von Kármán. Observant la correlació espacial del sensor situat al punt oposat al d'estancament (180°), es veu de nou la asimetria entre la part superior i la inferior del cilindre.

Resumint, es pot afirmar que, tot i la senzillesa aparent del cilindre circular, les dades de flux turbulent al seu voltant presenten una gran complexitat que suposa un repte a l'hora de ser capturada per les xarxes neuronals artificials.

3A.4 Característiques de les xarxes neuronals artificials emprades (ANN)

En aquest treball, s'usa l'algoritme Fuzzy ARTMap (FAM), descrit a fons al capítol 2. En tractar-se d'un algoritme d'entrenament supervisat, les dades experimentals, descrites en les seccions anteriors, són emprades per intentar aconseguir que l'ANN relacioni les entrades i les sortides que se li subministraran, tot capturant la dinàmica del sistema. Dels dos mòduls ART dels quals es compon una xarxa Fuzzy ARTMap, el mòdul ART^a s'encarregarà de classificar els patrons d'entrada, mentre que el mòdul ART^b classificarà els patrons de sortida. Els patrons d'entrada es componen d'una combinació espacial i temporal de coeficients de pressió (C_p). La principal tasca que cal realitzar durant la caracterització de les xarxes emprades en aquest treball és determinar la combinació òptima de valors temporals i espacials; és a dir, quantes dades anteriors en el temps al que es vol predir i quants sensors veïns del que es vol predir són necessaris per capturar la dinàmica del sistema. Els patrons de sortida es componen, únicament, del valor de C_p que es vol predir a partir del patró d'entrada. A continuació, es mostra la representació d'una combinació patró d'entrada/sortida.

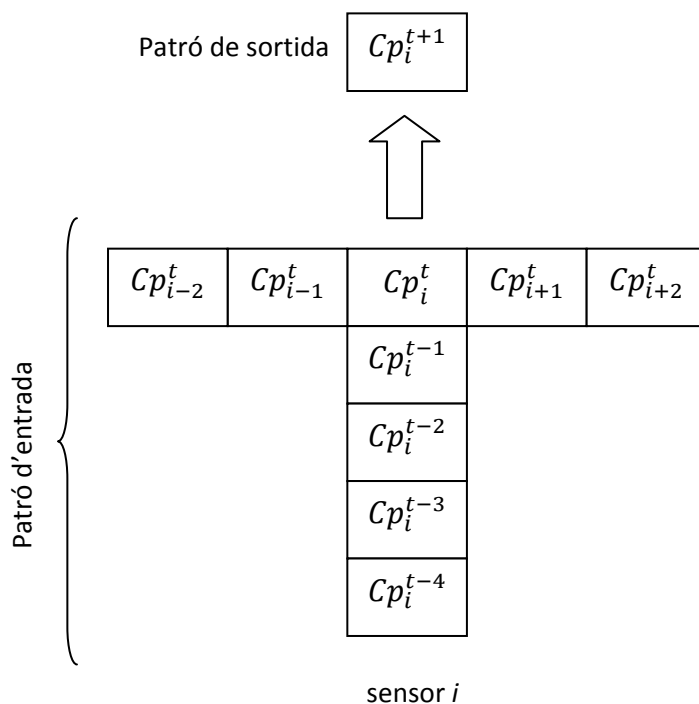


Fig. 3A.9. Esquema d'una combinació patró d'entrada/sortida.

El patró d'entrada que mostra la figura 3A.9 es compon de dades d'un sol instant previ de 4 sensors veïns del que es vol predir i de dades de 4 instants previs del sensor que es vol predir. D'ara en endavant s'utilitzarà la nomenclatura FAM_{a,b,c} per referir-nos a les combinacions espacials i temporals dels patrons d'entrada. La lletra *a* indica el nombre total de sensors que aporten dades al patró, la lletra *b* indica el nombre d'instants previs emprats provinents dels sensors veïns i la lletra *c* indica el nombre d'instants previs emprats provinents dels sensors d'aquell al qual es vol predir el coeficient de pressió.

Per tant, el cas de l'exemple de la figura 3A.9 s'anomenaria $FAM_{5,1,5}$. A continuació, es mostra un resum de les 6 combinacions de patrons d'entrada que es mostraran en aquest treball.

Combinació	Nombre de sensors implicats, a	Nombre d'instants de temps, b/c	Dimensions del patró d'entrada
$FAM_{5,1,5}$	5	1/5	9
$FAM_{5,4,12}$	5	4/12	28
$FAM_{8,1,1}$	8	1/1	8
$FAM_{32,1,1}$	32	1/1	32
$FAM_{32,4,4}$	32	4/4	128
$FAM_{32,11,11}$	32	11/11	352

Taula 3A.1. Resum de la combinació de dades temporals i espacials emprades en els patrons d'entrada al mòdul ART^a.

Seguint l'esquema de la figura 3A.9, cada valor de C_p al temps $t + 1$ del sensor i serà predit per una xarxa FAM alimentada per alguna de les combinacions mostrades a la taula 3A.1. Per tant, un cop les xarxes han estat entrenades, la funció dels sensors és rellevada per les xarxes FAM, és a dir, les xarxes generen els coeficients de pressió per a cada una de les 32 posicions sobre la superfície del cilindre. Com que cada FAM requereix informació de les FAM veïnes, a temps anteriors, totes han d'operar en paral·lel de forma simultània. En començar el procés de generació de noves sèries temporals de coeficients de pressió (predicció), cal iniciar les FAM amb la quantitat de dades temporals requerides segons la combinació de patrons escollida. Aquestes dades, lògicament, han de ser experimentals i en cap cas emprades durant l'entrenament de la xarxa. Un cop iniciat el procés de predicció, el conjunt de xarxes FAM és autosuficient i es retroalimenta amb les prediccions de temps anteriors.

3A.5 Resultats

Una primera avaluació del rendiment de les sis combinacions de patrons d'entrada, descrites a la taula 3A.1, és el càlcul de l'error entre els valors experimentals i els estimats de la desviació estàndard dels coeficients de pressió (C_p), dels coeficients de sustentació (C_s) i dels coeficients d'arrossegament (C_A). El coeficient d'arrossegament es calcula de forma similar al de sustentació (equació 3A.2), però aquest cop s'avaluen les forces en sentit horitzontal enlloc d'en sentit vertical.

$$C_A(t) = \sum_{i=1}^{32} \frac{\pi}{32} \cdot C_p(\theta, t) \cdot \cos \theta \quad (3A.4)$$

Per a C_A i C_s , aplicant les equacions 3A.2 i 3A.4 s'obtenen les sèries temporals dels dos coeficients i a continuació se'n calculen les desviacions estàndard (\tilde{C}_s i \tilde{C}_A), tant per a les sèries temporals experimentals com per a les estimades per les ANN. A la taula

3A.2, s'hi mostren els errors relatius en % de l'estimació dels dos coeficients per a les diverses combinacions de patrons d'entrada (ε_A i ε_S , respectivament). A la mateixa taula també es mostra l'error relatiu mitjà de l'estimació de la desviació estàndard dels coeficients de pressió (\tilde{C}_p).

$$\varepsilon_p = \sum_{i=1}^{32} \left| \frac{(\tilde{C}_{pi,est} - \tilde{C}_{pi,exp})}{\tilde{C}_{pi,exp}} \right| \quad (3A.5)$$

Arquitectura	ε_S (%)	ε_A (%)	ε_p (%)
FAM _{5,1,5}	-37	-1,1	15
FAM _{5,4,12}	-49	-33	29
FAM _{8,1,1}	-28	-12	6,6
FAM _{32,1,1}	-8,9	-1,5	4,4
FAM _{32,4,4}	2,1	-1,4	1,8
FAM _{32,11,11}	3,2	-7,5	0,2

Taula 3A.2. Error en la predicció de la desviació estàndard dels coeficients de pressió, sustentació i arrossegament per a cada arquitectura de xarxa emprada.

Cal fer notar que si es pren la desviació estàndard com el moment estadístic adequat per mesurar el rendiment de les FAM és perquè una estimació precisa de les fluctuacions en els tres coeficients té més importància que una estimació precisa de la mitjana. En l'estudi de la càrrega aerodinàmica a la qual és sotmès un cos, són els valors extrems els que s'han de tenir en compte per sobre dels valors mitjans, ja que són els que indiquen les càrregues màximes a les quals és sotmès el cos en qüestió.

A la figura 3A.10, s'hi representen els valors de la desviació estàndard dels coeficients de pressió (\tilde{C}_p) estimats per les xarxes per a cada sensor i els valors experimentals corresponents.

Observant la taula 3A.2 i la figura 3A.10, hom pot veure com els millors resultats s'obtenen emprant els trenta-dos valors espacials (FAM₃₂). En canvi, quan només s'empren quatre o set valors espacials (FAM₅ i FAM₈, respectivament) les xarxes només són capaces de capturar, de forma aproximada, les fluctuacions dels coeficients de pressió pròxims al punt d'estancament, mentre que per a la zona aigües avall dels punts de separació, les prediccions empitjoren notablement. Aquest fet indica que possiblement és necessari disposar d'informació de tota la superfície del cilindre perquè les xarxes puguin captar la dinàmica del sistema, tal com ho fan per a les xarxes FAM₃₂.

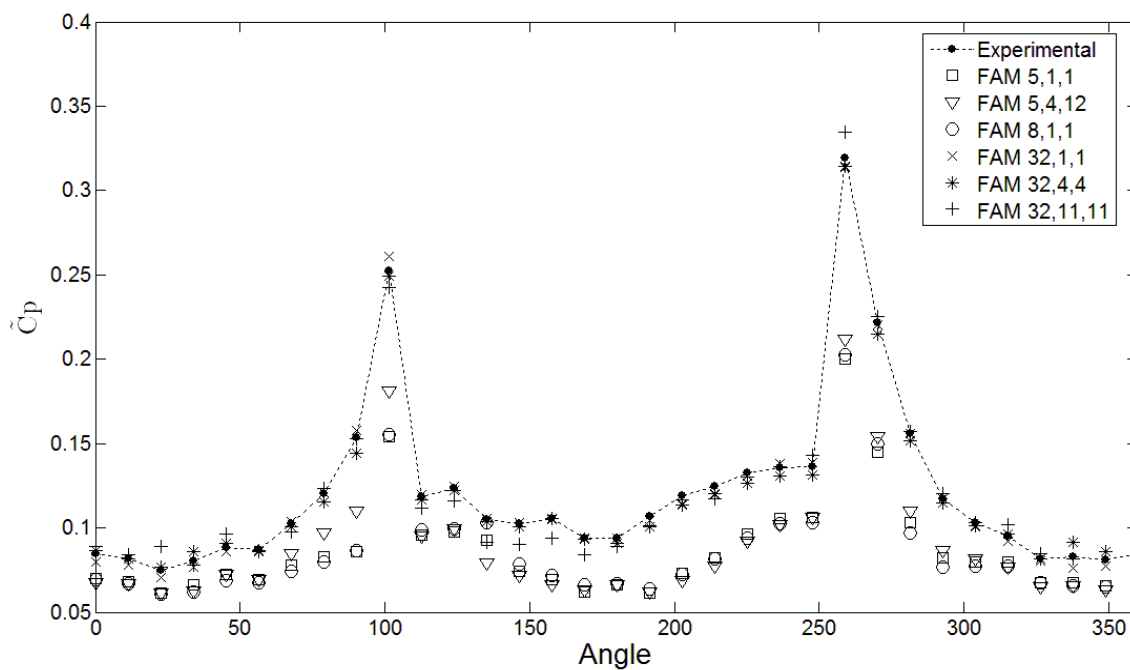



Fig. 3A.10. Desviació estàndard dels coeficients de pressió (\hat{C}_p) estimats per les xarxes comparats amb els valors experimentals.

Representant la correlació espacial per al sensor situat al punt d'estancament (0°) i per al sensor situat a la zona de separació (101°) (figura 3A.11), emprant els coeficients de pressió estimats per les xarxes FAM, es pot veure com, un cop més, les xarxes FAM₅ i FAM₈ obtenen mals resultats, ja que els coeficients de correlació amb els sensors adjacents disminueixen d'una forma molt més acusada del que li correspon si hom observa les dades experimentals.



a)




Fig. 3A.11. Correlació espacial experimental i estimada del sensor situat a la posició a) 0° i b) 101° respecte a la resta de sensors situats sobre la superfície d'un cilindre circular.

Les xarxes FAM₅ i FAM₈ utilitzen 4 i 7 valors, respectivament, de sensors adjacents i, per tant, es podria esperar que l'estimació del coeficient de correlació dels sensors adjacents fos correcta. El fet que no sigui així reafirma la hipòtesi que cal informació de tota la superfície del cilindre perquè les xarxes capturin la dinàmica del sistema de forma correcta.





Fig. 3A.12. Correlació espacial experimental i estimada del sensor situat a 90° respecte a la resta de sensors situats sobre la superfície d'un cilindre circular.

Si hom es fixa amb les xarxes FAM_{32} , pot veure com els resultats per a les xarxes $FAM_{32,1,1}$ i $FAM_{32,4,4}$ són millors que per a la xarxa $FAM_{32,11,11}$. Es pot observar de forma molt més clara en la correlació espacial per al sensor situat a 90° (figura 3A.12), on els resultats per a la xarxa $FAM_{32,11,11}$ són molt dolents, mentre que per a la resta de xarxes FAM_{32} continuen essent bons. *A priori*, sembla que com més informació temporal es doni a la xarxa, millors resultats ha d'obtenir, però, com es pot veure, no és així. Aquest fet es pot explicar a través de l'escala temporal integral, és a dir, la freqüència que governa el sistema dinàmic. Com ja s'ha vist abans, aquesta freqüència varia depenent de la zona sobre el cilindre. Sobre el punt d'estancament, l'escala temporal integral és més baixa que sobre la zona dels punts de separació, on es mescla l'efecte del despreniment de vòrtexs amb el de la turbulència del corrent lliure. A la figura 3A.13, s'hi pot apreciar com la xarxa $FAM_{32,11,11}$ obté funcions d'autocorrelació desfasades respecte a les experimentals, especialment en el cas del punt de separació (figura 3A.13b). Aquest fet mostra que la xarxa no ha capturat de forma correcta l'evolució temporal de la turbulència, i indica que un excés d'informació temporal en els vectors d'entrada de les xarxes és contraproductiu. Per al cas del punt d'estancament (figura 3A.13a), la xarxa $FAM_{32,4,4}$ obté una autocorrelació força similar a l'experimental dins l'escala temporal integral de la turbulència al corrent lliure (0,025 s) i obté els mateixos bons resultats per al punt de separació (figura 3A.13b) fins a un desfasament de 0,04 s; sobreestima així la resta d'autocorrelació dins el cicle temporal del despreniment de vòrtexs (aproximadament 0,09 s). Per tant, havent obtingut els millors resultats quan s'empren 4 valors temporals, que correspon aproximadament a la freqüència de la turbulència del corrent lliure, es pot dir que està directament relacionada amb la quantitat d'informació temporal òptima per a la construcció dels vectors d'entrada de les xarxes.






Fig. 3A.13. Autocorrelació experimental i estimada del sensor situat a la posició a) 0° i b) 101°.

Un cop determinat que la xarxa FAM_{32,4,4} és l'òptima, es comparen els valors de l'*skewness* dels coeficients de pressió estimats per aquesta xarxa i es comparen amb els valors experimentals.

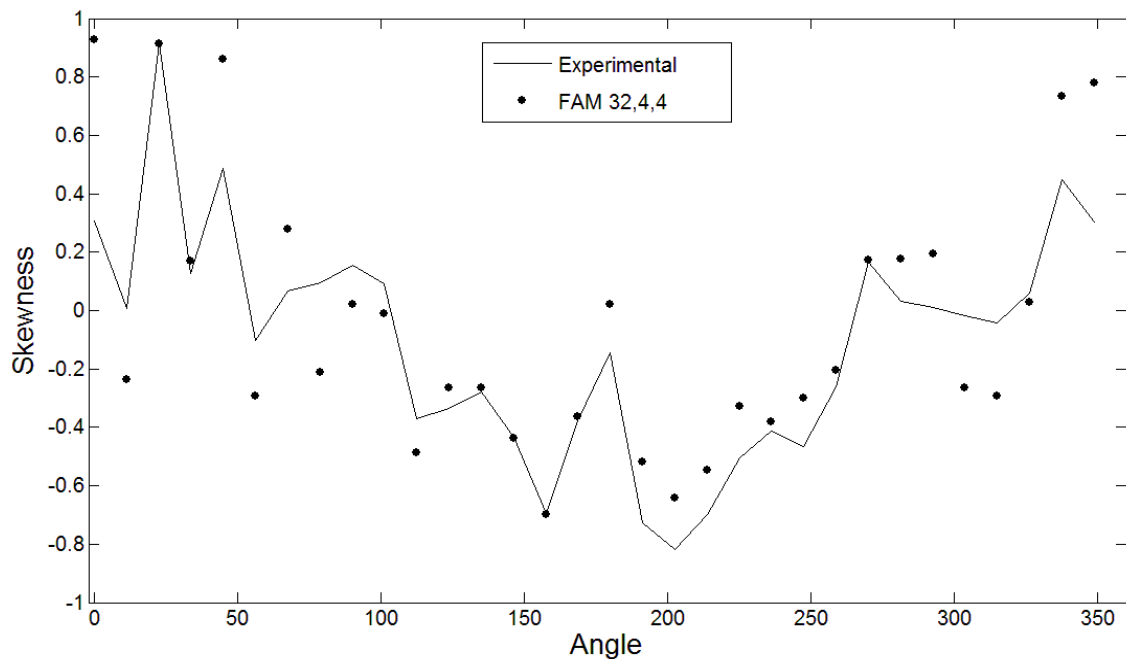


Fig. 3A.14. *Skewness* dels coeficients de pressió estimats (per la xarxa FAM_{32,4,4}) i experimentals per a cada sensor situat sobre la superfície del cilindre circular.

L'estimació de l'*skewness* és força acurada en la majoria de punts, i indica que la xarxa és capaç de capturar valors extrems, de gran importància en el càlcul de càrregues aerodinàmiques, objectiu últim del model. Cal fer notar que si hom compara la figura 3A.14 amb l'homònima publicada en l'article de Gavalda et al. (2009) adjunt a l'annex d'aquest treball, podrà veure que no són exactament iguals. Això es deu al fet que les dades emprades per realitzar la figura de l'article no eren les correctes. Tot i així, aquest error no varia cap de les conclusions exposades en aquell article.

3A.6 Conclusions

En primer lloc, s'ha comprovat la complexitat existent en el comportament temporal dels coeficients de pressió del sistema dinàmic estudiat, fet que dona més importància als bons resultats obtinguts i que permet assumir que les conclusions que se n'extreuen són aplicables a altres sistemes dinàmics de complexitat similar.

S'ha comprovat que les dades de pressió contenen prou informació del sistema perquè un model construït únicament amb aquestes dades pugui capturar-ne la dinàmica. A més, s'ha vist com, per a la construcció dels vectors d'entrada per als models, la informació espacial té més importància que la temporal. Perquè el model funcioni correctament, cal disposar d'informació sobre tota la superfície del cilindre, mentre que l'elecció de la quantitat d'informació temporal, tot i ésser important, no és un factor crític. S'ha vist que l'escala temporal integral de la turbulència del corrent lliure és la que governa el sistema, motiu pel qual, si s'usen més dades temporals que les contingudes per aquesta escala, les xarxes perden capacitat de generalització en les relacions entrada/sortida i el seu funcionament perd precisió.

Capítol 3B. Classificació i reconstrucció de sèries temporals de coeficients de pressió sobre un cilindre en condicions altament turbulentes

3B.1 Introducció

En aquesta part del treball, s'hi continua tractant el sistema dinàmic del cilindre circular immers en condicions de flux altament turbulent. Aquest cop es vol demostrar que mitjançant l'ús de xarxes neuronals artificials (ANN) és possible classificar les sèries temporals de pressions, obtingudes en diversos punts sobre la superfície del cilindre, a partir dels seus moments estadístics. D'aquesta manera es redueix enormement el volum de dades amb què treballen les ANN i s'identifiquen zones de similitud, en el comportament del fluid, sobre la superfície del cilindre.

S'ha escollit l'algoritme Self Organizing Maps (SOM) per realitzar les tasques de classificació, ja que el treball de Beltzer i Sato (2003), on utilitzaven xarxes SOM per classificar dades temporals de pressions sobre la superfície d'un edifici, indica que poden realitzar aquesta tasca de forma correcta.

Com en el treball anterior, es disposa de mesures temporals de pressió provinents de 32 sensors situats sobre la superfície del cilindre. L'objectiu de la classificació és poder escollir una sèrie temporal que representi cada zona de "similitud" i reconstruir, a partir d'ella, la resta de sèries temporals que formen part d'aquesta zona. En el treball anterior es generaven noves sèries temporals de pressió entrenant ANN amb dades temporals experimentals de les mateixes sèries. En canvi, en aquest treball es fa un pas endavant, s'entrenen les ANN únicament amb dades estadístiques de les sèries temporals. Només es requereixen les sèries temporals experimentals dels sensors escollits per l'ANN com a generadors de la resta, i es redueix així la quantitat de dades experimentals necessàries per realitzar el model de predicció.

El treball es divideix en quatre etapes ben diferenciades:

1. Classificació de les dades estadístiques dels 32 sensors.
2. Generació de noves sèries temporals de pressions a partir de la classificació realitzada.
3. Avaluació dels resultats obtinguts a partir d'un estudi de la precisió aconseguida en el càlcul de càrregues aerodinàmiques a partir de les noves sèries temporals generades.
4. Validació de la metodologia desenvolupada, repetint les tres primeres etapes amb conjunts de dades experimentals obtingudes en condicions d'operació (nombres de Reynolds) diferents.

3B.2 Dades experimentals

Les dades experimentals emprades en aquest treball han estat obtingudes en el mateix túnel de vent descrit al capítol 3A. A part del conjunt de dades ja comentat, es disposa de dos nous conjunts, mesurats de la mateixa forma i en les mateixes condicions, llevat de la velocitat del vent en el corrent lliure. Les dues noves velocitats de vent són 13,8 m/s i 6,5 m/s, que corresponen a un valor del nombre de Reynolds (Re) basat en el diàmetre del cilindre, de $4,5 \times 10^5$ i $2,2 \times 10^5$, respectivament. Aquests dos conjunts de dades serviran per comprovar que la metodologia de treball que es desenvoluparà en els següents punts, emprant el conjunt de dades amb $Re = 1,0 \times 10^6$, és igual de vàlida per a diferents valors de Re . Cal fer notar que els valors del nombre de Reynolds dels dos nous conjunts de dades ja no es consideren valors de Re postcrítics, sinó supercrítics (Basu, 1982).

Igual que per al capítol 3A, en tot moment es treballarà amb coeficients de pressió (C_p) calculats a partir de les mesures de pressió dels sensors (equació 3A.1).

3B.3 Característiques de les xarxes neuronals artificials emprades (ANN)

En aquest treball, s'usa l'algoritme Self Organizing Maps (SOM) per classificar les dades estadístiques extrems de les dades temporals de pressió, mesurades pels 32 sensors repartits sobre la superfície del cilindre (figura 3A.2). A continuació, s'empra l'algoritme de clusterització K-means per optimitzar l'agrupació dels patrons creats per SOM. Ambdós algorismes estan descrits a fons al capítol 2.

L'algoritme SOM usa un aprenentatge no supervisat i, per tant, no és necessari indicar-li els patrons de sortida que s'esperen, segons l'entrada que se li doni, durant l'entrenament. Com ja s'ha comentat en el treball anterior, en l'estudi de càrregues aerodinàmiques les fluctuacions de les dades temporals, siguin de coeficients de pressió, sustentació o arrossegament, tenen més importància que els valors mitjans. Per tant, centrarem la classificació, mitjançant SOM, de les dades de pressió, en les fluctuacions. A cadascuna de les dades de C_p de les 32 sèries temporals de pressions s'hi resta la seva mitjana (\bar{C}_p) i se'n calcula la desviació estàndard, la curtosi i l'*skewness*. Aquests tres moments estadístics conformen les tres dimensions de què estan compostos els patrons que classifica la xarxa SOM.

La xarxa SOM emprada té unes dimensions de 20×20 , configuració toroïdal i graella hexagonal. Les dimensions són fruit de diverses proves per buscar la minimització de l'error de qualitat (equació 2.6) i de l'error topogràfic (equació 2.7). Un cop entrenada la xarxa SOM amb els trenta-dos patrons de tres dimensions, la capa de projecció bidimensional de la xarxa queda organitzada de forma que els patrons amb característiques similars estan més pròxims entre ells. Cada neurona de la capa de projecció està representada per un vector bidimensional anomenat centroide. En aquest punt, l'algoritme de clusterització K-means s'encarrega d'agrupar els centroides de

forma que es minimitzi la distància entre membres d'un mateix grup o clúster i es maximitzi la distància entre membres de diferents grups o clústers (equació 2.8). Un cop la capa de projecció bidimensional està agrupada en clústers, només cal observar a quin clúster pertany. Depenent del nombre de clústers creats i del nombre de patrons per classificar, podem trobar clústers poblats amb uns quants patrons, només un patró o clústers als quals no correspon cap patró. Com que l'objectiu del procés de classificació és trobar un membre de cada clúster capaç de representar la resta, s'escollirà de la manera següent:

1. Si un clúster està format per uns quants patrons, es calcula la distància euclidiana mitjana entre ells, tenint únicament en compte dues de les seves dimensions (l'*skewness* i la curtosi). No es té en compte la desviació estàndard, ja que, com es veurà més endavant, serà modificada en el procés de generació de les sèries temporals. Escollint el patró amb la distància euclidiana més baixa, s'aconsegueix un patró representant que té l'*skewness* i la curtosi més semblants possible a la resta de patrons que conformen el clúster.
2. Si un clúster està format per només dos patrons, la distància euclidiana mitjana entre ells serà la mateixa. Per tant, qualsevol dels dos pot fer de representant del clúster.
3. Si un clúster està format únicament per un sol patró, no podrà ésser generat per cap altre patró. Aquests casos es donen en les zones sobre el cilindre on l'estructura del flux turbulent és més complexa i, per tant, és més difícil trobar una altra zona amb un comportament prou similar.

3B.4 Generació de les sèries temporals

Un cop escollit el patró representant de cada clúster, es pot procedir a generar les sèries temporals dels coeficients de pressió. Es generen únicament les sèries dels sensors que han estat assignats a clústers amb dos o més membres. La resta no es pot generar i, per tant, en els càlculs posteriors s'hauran d'emprar les sèries experimentals corresponents.

Com ja s'ha comentat abans, per dur a terme la classificació dels patrons s'ha treballat a partir de les fluctuacions (C_p') de les sèries temporals dels coeficients de pressió, dels quals s'ha calculat els moments estadístics. Mitjançant una simple transformació, és possible canviar la desviació estàndard d'una sèrie temporal de fluctuacions per la d'una altra. Si λ és un nombre real i $f(x)$ la sèrie temporal de fluctuacions, en aplicar la transformació $f(x) = \lambda \cdot x$ la desviació estàndard (RMS) de $\lambda \cdot x$ és igual a $\lambda \cdot RMS(x)$. Per tant, multiplicant la sèrie temporal de fluctuacions del sensor generador per la RMS del sensor que es vol generar i dividint-la per la RMS del sensor generador,

s'aconsegueix una sèrie temporal de fluctuacions amb un comportament similar al del sensor que es vol generar i amb el valor exacte de la seva pròpia RMS,

$$C'_{p,i}(t) = C'_{p,j}(t) \frac{\tilde{C}'_{p,i}}{\tilde{C}'_{p,j}} \quad (3B.1)$$

on \tilde{C}'_p és la fluctuació de la desviació estàndard del coeficient de pressió, i fa referència al sensor generant i j al sensor generador.

Ja només cal sumar el valor de la mitjana $\bar{C}_{p,i}$ a la sèrie temporal de fluctuacions $C'_{p,i}(t)$ generada per obtenir una sèrie temporal de coeficients de pressió $C_p(t)$ completa. Cal fer notar que en la generació de les sèries temporals només es tenen en compte la mitjana i la desviació estàndard experimentals dels sensors generats. Per aquest motiu és important que, en la selecció del patró representant de cada clúster, tingui l'*skewness* i la curtosi tan semblant com sigui possible als patrons que representa, ja que servirà de base per generar les sèries temporals de coeficients de pressió.

3B.5 Resultats

Amb la xarxa SOM entrenada, s'han realitzat unes quantes clusteritzacions amb l'algoritme K-means. Com que *a priori* no es coneix el nombre exacte de clústers que es vol crear, es fan diverses proves, variant-ne el nombre, de les quals se'n presentaran quatre en aquest treball. Cal recordar que aplicant l'algoritme K-means, indica quin és el nombre òptim de clústers basant-se en l'índex de Davies-Bouldin (equació 2.8). Aquest òptim només té en compte factors topogràfics del camp de projecció bidimensional de la xarxa SOM. Tot i que és una bona indicació del nombre òptim de clústers, en aquest treball no es té en compte únicament el nombre de clústers amb l'índex de Davies-Bouldin més baix, sinó el conjunt de nombre de clústers amb valors baixos de l'esmentat índex. D'aquesta forma es disposa d'un rang prou ampli de nombre de clústers, que permet estudiar l'efecte en la precisió del càlcul de càrregues aerodinàmiques segons la quantitat de sèries temporals experimentals emprades.

Primer es treballa amb el conjunt de dades amb el nombre de Reynolds igual a $1,0 \times 10^6$. En les següents taules es presenten quatre classificacions de les dades dels trenta-dos sensors (patrons) de pressió. El valors numèrics fan referència als sensors en la disposició mostrada a la figura 3A.2. Cada classificació indica el nombre total de clústers creats (que continguin almenys un patró) i mostra els sensors que han estat classificats, com a mínim, amb un altre sensor en el mateix clúster, separant el sensor escollit com a generador dels que seran generats per aquest sensor.

a)

9 clústers		
Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)
1	26	9
2	10	25
3	31	1, 5, 32
4	2	4, 6, 29
5	30	7, 8, 17, 27, 28
6	22	11, 12, 13, 14, 16, 21, 23
7	20	15, 18, 19

b)

17 clústers		
Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)
1	32	1
2	4	2
3	5	31
4	29	6
5	26	9
6	11	12
7	30	7, 28
8	16	13, 14
9	20	15, 18, 19
10	23	21, 22

c)

22 clústers		
Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)
1	29	2
2	5	31
3	28	7
4	11	12
5	14	16
6	20	15, 18, 19
7	23	21, 22

d)		25 clústers	
Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)	
1	32	1	
2	5	31	
3	7	28	
4	26	9	
5	11	12	
6	20	19	
7	23	22	

Taula 3B.1. Clusterització dels trenta-dos patrons del conjunt de dades amb $Re = 1,0 \times 10^6$ emprant a) 9 clústers, b) 17 clústers, c) 22 clústers i d) 25 clústers.

Si ens fixem, per exemple, en la taula 3B.1a, veurem que dels 9 clústers, només 7 tenen dos o més patrons. Això vol dir que els altres 2 només contenen 1 patró. Si comptem tots els patrons classificats en els 7 clústers, tenim un total de 30 patrons, que sumats als 2 que s'han classificat en clústers d'un sol patró, tenim els 32 patrons provinents dels 32 sensors amb què s'ha entrenat la xarxa SOM.

Com era d'esperar, en augmentar el nombre de clústers, augmenta la probabilitat de trobar-nos clústers amb només un patró, mentre que per a nombres baixos de clústers, en trobem de molt poblats. Com es veurà en els resultats que es mostren a continuació, quan es treballa amb nombres de clústers baixos, els patrons no tenen prou llibertat per classificar-se correctament. El nombre de clústers òptim també dependrà de quin sigui el criteri de reducció de dades experimentals, és a dir, com menys clústers hi hagi es generaran més sèries temporals i, per tant, es necessitaran menys dades experimentals.

A continuació, es presenten els resultats obtinguts en el càlcul de les càrregues aerodinàmiques a què és sotmès el cilindre. Mitjançant la metodologia descrita en la secció anterior, es generen les sèries temporals de C_p dels sensors i a partir dels sensors j per als quatre casos que es mostren a la taula 3B.1. Les càrregues aerodinàmiques que es calculen són el coeficient de sustentació C_S (equació 3A.2) i el coeficient d'arrossegament C_A (equació 3A.5).

		Experimental	9 clústers	17 clústers	22 clústers	25 clústers
C_S	Mitjana	0,1717	0,1717	0,1717	0,1717	0,1717
	RMS	0,1475	0,0360	0,1114	0,1342	0,1208
C_A	Mitjana	0,5113	0,5113	0,5113	0,5113	0,5113
	RMS	0,0558	0,0931	0,0667	0,0567	0,0565



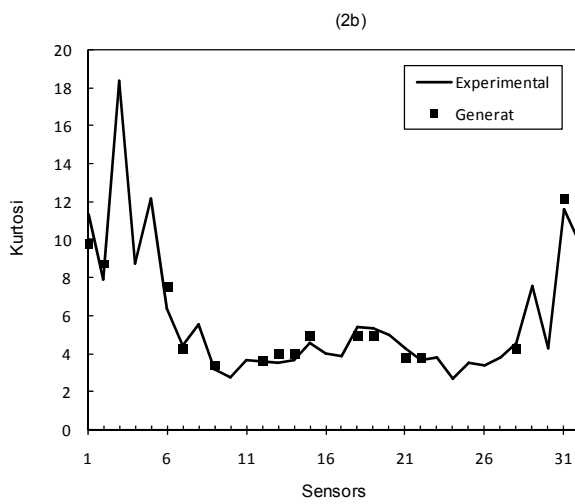



Taula 3B.2. Càrregues aerodinàmiques calculades a partir de la combinació de sèries temporals de C_p experimentals i generades per a les quatre clusteritzacions realitzades per al conjunt de dades amb $Re = 1,0 \times 10^6$.

En primer lloc, cal dir que com menys clústers conté la classificació, més sèries temporals generades s'usen en el càlcul de les càrregues aerodinàmiques, fet que contribueix a augmentar l'error en el càlcul. Observant la taula 3B.2, es pot apreciar la tendència de millora en la precisió dels coeficients de sustentació i arrossegament fins al cas on s'usen 22 clústers. Amb 25 clústers ja empitjora el càlcul de C_S i es manté constant el de C_A . Tenint en compte que com més clústers, més dades experimentals s'empren en el càlcul de les càrregues aerodinàmiques, es pot afirmar que existeix un valor òptim en què, en augmentar el nombre de clústers, ja no s'obté una millor classificació dels patrons. Per poder apreciar millor aquesta tendència, en la següent taula es mostren els percentatges d'error del càlcul de l'RMS d'ambdós coeficients, junt amb el percentatge de dades generades usades en el càlcul. No es mostren els percentatges en el cas de la mitjana dels coeficients, ja que, com es pot veure a la taula 3B.2, es calculen de forma precisa i l'error és del 0%. Això es deu al fet que, durant l'operació de generació de les sèries temporals, prenen el valor experimental de la mitjana que correspon a cada sensor. En el cas de l'RMS, també s'usa el corresponent valor experimental, però, en el càlcul de C_S i C_A , l'RMS varia, mentre que la mitjana no.

		9 clústers	17 clústers	22 clústers	25 clústers
Error relatiu %	\tilde{C}_S	75,6	24,5	9,0	18,1
	\tilde{C}_A	66,9	19,6	1,6	1,3
% dades generades		72	47	31	22

Taula 3B.3. Error relatiu de la desviació estàndard dels coeficients de sustentació i arrossegament per a les 4 clusteritzacions realitzades per al conjunt de dades amb $Re = 1,0 \times 10^6$.

Un cop vist que es poden aconseguir valors de càrregues aerodinàmiques força precisos depenent del nombre de clústers emprat i, per tant, de la quantitat de dades temporals generades en el seu càlcul, es procedeix a avaluar la precisió individual en la generació de les sèries temporals de C_p . En primer lloc, es calcula l'*skewness* i la curtosi de totes les sèries temporals generades i es comparen amb els seus valors experimentals. Es recorda un cop més que la mitjana i la desviació estàndard de les sèries temporals generades és exactament igual que el de les sèries experimentals a causa del procés de generació emprat, i que, per tant, no té sentit mostrar-ne la comparació. En les següents figures, s'hi mostra la comparació de l'*skewness* i la curtosi de les sèries experimentals i generades per a les quatre clusteritzacions realitzades.






Fig. 3B.1. Valors del a) *skewness* i b) curtosi de les sèries temporals de C_p experimentals i generades a les quatre clusteritzacions realitzades compostes per 1) 9 clústers, 2) 17 clústers, 3) 22 clústers i 4) 25 clústers per al conjunt de dades amb $Re = 1,0 \times 10^6$.

Observant la figura 3B.1, es pot veure com en general els valors de l'*skewness* i la curtosi de les sèries temporals de C_p generades són força similars als experimentals. Per poder comparar millor els resultats entre les quatre clusteritzacions, a continuació es mostra una taula amb l'error absolut mitjà entre els valors dels *skewness* i la curtosi de les sèries experimentals i generades.

		9 clústers	17 clústers	22 clústers	25 clústers
Error absolut	<i>Skewness</i>	0,078	0,057	0,051	0,065
	Curtosi	0,495	0,497	0,323	0,433

Taula 3B.4. Error absolut mitjà entre els valors dels *skewness* i la curtosi de les sèries experimentals i generades de C_p per a les 4 clusteritzacions per al conjunt de dades amb $Re = 1,0 \times 10^6$.

Com ja s'ha vist en el càlcul de les càrregues aerodinàmiques, la clusterització amb 22 clústers és la que obté millors resultats. A més, en el cas del càlcul de l'error de l'*skewness* i la curtosi, només es tenen en compte les sèries temporals corresponents als sensors generats, a diferència del cas de les càrregues aerodinàmiques, en què calia emprar les sèries dels 32 sensors per poder calcular els coeficients de sustentació i arrossegament. És a dir, que, en aquest cas, l'error calculat per a cada clusterització no està influït pel percentatge de sèries temporals generades.

Per acabar d'estudiar la precisió en la generació de les sèries temporals dels coeficients de pressió, es comparen els autoespectres de quatre de les sèries generades per a la clusterització amb 22 clústers amb els respectius autoespectres de les sèries experimentals.

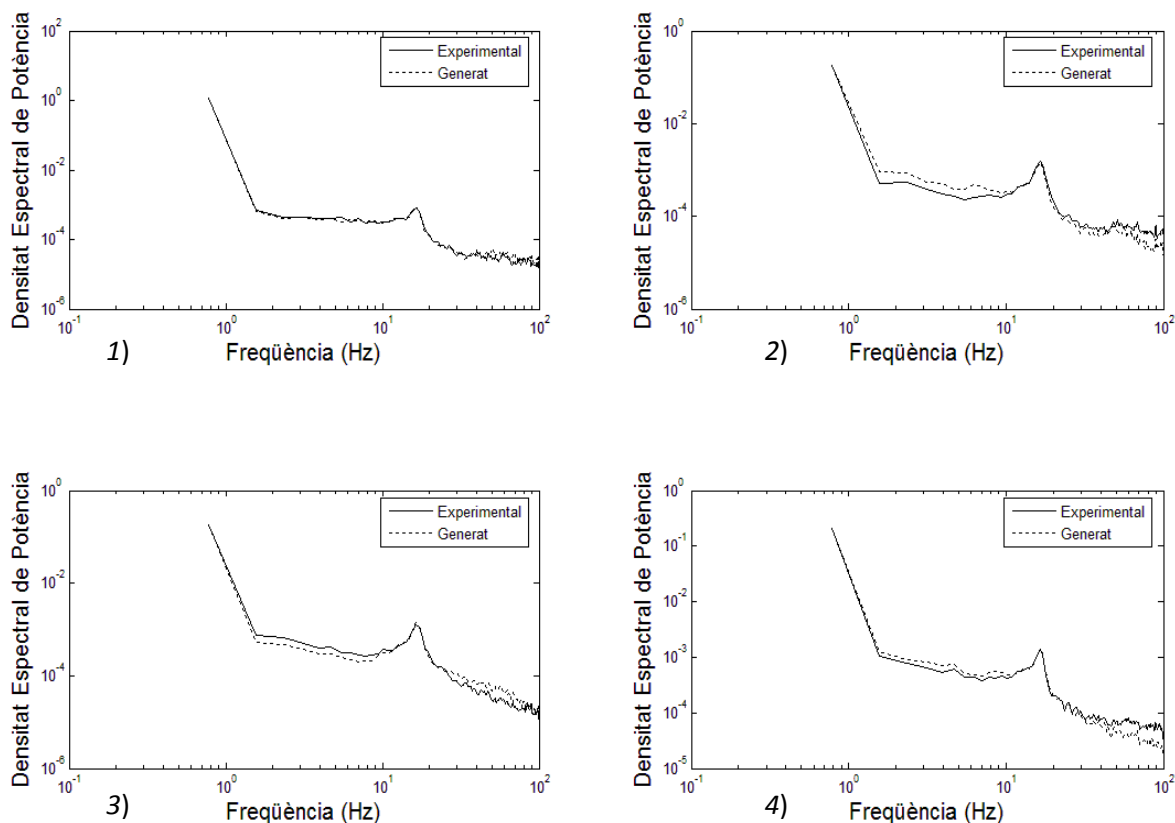


Fig. 3B.2. Autoespectres de les sèries experimentals i generades de coeficients de pressió corresponents als sensors 1) #7, 2) #12, 3) #19 i 4) #22 emprant la clusterització amb 22 clústers per al conjunt de dades amb $Re = 1,0 \times 10^6$.

Mirant la figura 3B.2, es pot veure com els autoespectres de les sèries generades segueixen la tendència de les experimentals en tot el rang de freqüències i, més concretament, en el pic de densitat espectral de potència, fet que indica que les sèries temporals de C_p generades reproduïen de forma correcta la dinàmica del fluid turbulent que representen.

Un cop s'ha determinat el nombre de clústers òptim, és possible afinar una mica més la clusterització. Amb això, el que es vol dir és que amb la metodologia seguida fins ara s'han escollit els sensors generadors seguint de manera automàtica els resultats obtinguts amb la clusterització amb SOM i K-means. Si es dona el cas que es vulgui reduir l'error de l'RMS dels coeficients de sustentació i arrossegament i l'error mitjà de l'*skewness* i la curtosi dels coeficients de pressió, es poden excloure les sèries generades que influeixen més en aquests errors. Cal dir que, en excloure algunes de les sèries generades, han de ser substituïdes per sèries experimentals i que per, tant, es redueix la capacitat de generalització. És a dir, cal fer un balanç entre la precisió mitjana desitjada de les sèries temporals generades i la quantitat de sèries experimentals que s'utilitzaran. La taula 3B.1c conté la relació de sensors generats per a la clusterització que ha obtingut millors resultats. Dels 10 sensors generats, se n'han trobat 3 que són els que es generen d'una forma menys eficaç que la resta. Aquests sensors són el #7, el #19 i el #31 (figura

3A.2). A la taula següent es mostra la nova relació de sensors generats, on s'exclouen els 3 esmentats.

Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)
1	11	12
2	14	16
3	29	2
4	20	15, 18
5	23	21, 22

Taula 3B.5. Clusterització afinada dels trenta-dos patrons del conjunt de dades amb $Re = 1,0 \times 10^6$.

Generant únicament les 7 sèries temporals de C_p que es mostren a la taula 3B.5, s'han obtingut els resultats següents:

	Experimental	Generat	Error (%)
\tilde{C}_S	0,1475	0,1454	1,4
\tilde{C}_A	0,0558	0,0557	0,2

Taula 3B.6. Error relatiu i valors de la desviació estàndard dels coeficients de sustentació i arrossegament per a la clusterització afinada realitzada per al conjunt de dades amb $Re = 1,0 \times 10^6$.

Sensor	Skewness			Curtosi		
	Experimental	Generat	Error absolut	Experimental	Generat	Error absolut
#2	0,008	-0,043	0,051	7,891	7,571	0,320
#12	-0,337	-0,369	0,032	3,563	3,663	0,100
#15	-0,694	-0,699	0,005	4,569	4,986	0,417
#16	-0,378	-0,434	0,057	3,989	3,688	0,301
#18	-0,726	-0,699	0,027	5,402	4,986	0,416
#21	-0,505	-0,466	0,039	4,264	3,784	0,480
#22	-0,412	-0,466	0,054	3,640	3,784	0,144
Mitjana			0,038			0,311

Taula 3B.7. Error absolut i valors de $skewness$ i la curtosi de les sèries temporals de C_p experimentals i generades per als 7 sensors generats en la clusterització afinada per al conjunt de dades amb $Re = 1,0 \times 10^6$.

Comparant els resultats entre la clusterització amb 22 clústers i la mateixa un cop afinada, es pot veure com l'última millora en els quatre paràmetres avaluats. Redueix l'error relatiu en l'estimació de la desviació estàndard del coeficient de sustentació (\tilde{C}_S)

ja que passa d'un 9,0% a un 1,4%, i d'un 1,6% a un 0,2% en el cas del coeficient d'arrossegament (\tilde{C}_A). Pel que fa a l'*skewness* i la curtosi de les sèries temporals dels coeficients de pressió, el primer passa de tenir un error absolut mitjà de 0,051 a 0,038 i el segon, d'un 0,323 a un 0,311. Recordem un cop més que l'augment de la precisió en els quatre paràmetres estudiats té com a contrapartida l'augment del nombre de sèries experimentals necessàries, o, el que és el mateix, la reducció de sèries temporals que es generen, que en aquest cas es passa d'un 31% a un 22% per a la clusterització afinada.

3B.5.1 Validació de la metodologia emprada

Per validar la metodologia per a la clusterització de les sèries experimentals dels coeficients de pressió emprada fins ara, es prova si es continua obtenint bons resultats quan el conjunt de dades experimentals ha estat mesurat en condicions de nombre de Reynolds diferents. Com ja s'ha esmentat abans, es disposa de dos nous conjunts de dades amb nombres de Reynolds de $4,5 \times 10^5$ i $2,2 \times 10^5$, que, tot i que continuen sent altament turbulents, ja no es consideren valors de *Re* postcrítics, sinó supercrítics (Basu, 1982). Això suposa que l'estructura de la turbulència no serà la mateixa i *a priori* es pot suposar que les clusteritzacions seran diferents, és a dir, els sensors s'agruparan de forma diferent que el del cas emprat durant el desenvolupament de la metodologia. El que es vol comprovar és si, tot i que la formació de clústers variarà, l'eficiència del mètode continua sent bona.

Per facilitar la comparació entre els dos nous conjunts de dades i el de $Re = 1,0 \times 10^6$, s'utilitzen clusteritzacions en les quals es generen dades temporals de 10 sensors (31% del nombre total de sensors), que corresponen al mateix nombre de sensors generats en la clusterització que havia donat millors resultats per al primer conjunt de dades.

Entrenant xarxes SOM de les mateixes característiques que l'emprada per al primer conjunt de dades i aplicant l'algoritme de clusterització K-means, s'obtenen les classificacions següents:

a)		
$Re = 4,5 \times 10^5$		
Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)
1	27	1
2	31	2
3	13	3
4	10	24
5	21	22
6	26	25
7	19	6, 17
8	18	15, 16

b)

	$Re = 2,2 \times 10^5$	
Clúster	Sensor generador ($j = 1$)	Sensors generats ($i = 1, \dots, n$)
1	11	17
2	14	20
3	25	26
4	32	29
5	9	16, 18
6	19	23, 24
7	13	12, 10

Taula 3B.8. Clusterització dels trenta-dos patrons del conjunt de dades amb a) $Re = 4,5 \times 10^5$ i b) $Re = 2,2 \times 10^5$.

Per a cada clusterització es generen les corresponents sèries temporals de C_p , seguint la metodologia descrita en la secció anterior, i es calculen les càrregues aerodinàmiques a les quals és sotmès el cilindre.

a)

		$Re = 4,5 \times 10^5$		$Re = 2,2 \times 10^5$	
		Experimental	Generat	Experimental	Generat
C_S	Mitjana	0,0923	0,0923	0,0422	0,0422
	RMS	0,1075	0,1033	0,3348	0,3440
C_A	Mitjana	0,3864	0,3864	0,2927	0,2927
	RMS	0,0775	0,0790	0,2840	0,3166

b)

		$Re = 4,5 \times 10^5$	$Re = 2,2 \times 10^5$
Error relatiu %	\tilde{C}_S	3,9	2,8
	\tilde{C}_A	1,9	11,5

Taula 3B.9. a) Càrregues aerodinàmiques calculades a partir de la combinació de sèries temporals de C_p experimentals i generades per als conjunts de dades amb $Re = 4,5 \times 10^5$ i $Re = 2,2 \times 10^5$ i b) error relatiu de la desviació estàndard en el càlcul dels coeficients de sustentació i arrossegament.

Comparant els resultats de la taula 3B.9b i els de la taula 3B.3, es pot veure com els errors en el càlcul d'ambdós coeficients de càrregues aerodinàmiques són, fins i tot, més baixos en tots els casos, excepte per a la desviació estàndard del coeficient d'arrossegament per al cas de $Re = 2,2 \times 10^5$.

A continuació, es calcula l'*skewness* i la curtosi de totes les sèries temporals generades i es comparen amb els seus valors experimentals.

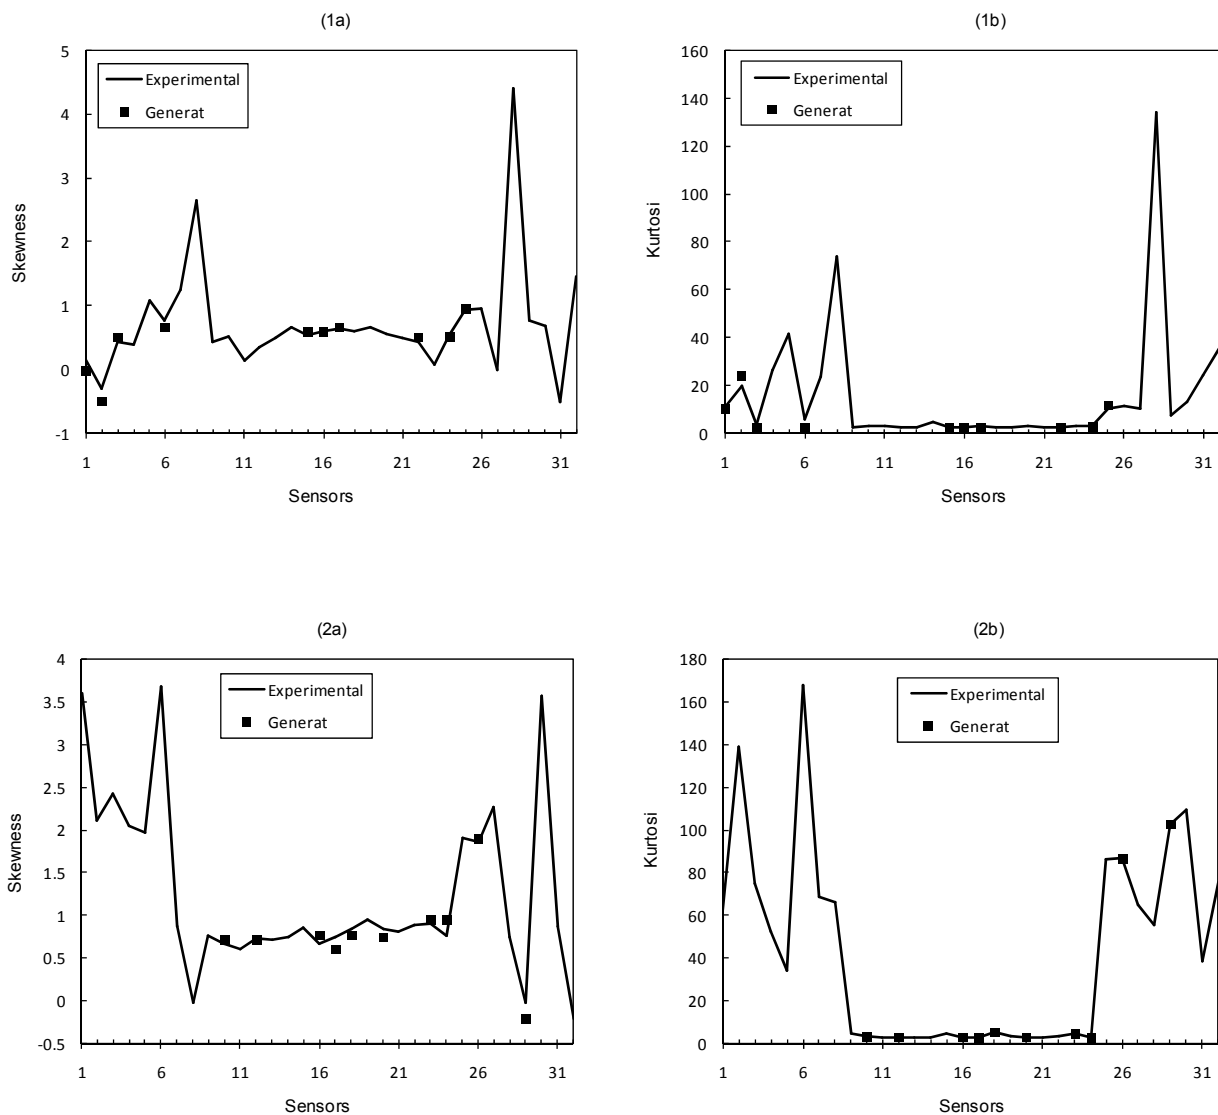


Fig. 3B.3. Valors de a) *skewness* i b) *curtosi* de les sèries temporals de C_p experimentals i generades a conjunts de dades amb 1) $Re = 4,5 \times 10^5$ i 2) $Re = 2,2 \times 10^5$.

Observant la figura 3B.3, es pot veure com els valors de l'*skewness* i la *curtosi* de les sèries temporals generades són, en la majoria dels casos, gairebé idèntics als de les sèries experimentals. En aquest cas, no es mostra una taula amb els errors absoluts mitjans dels *skewness* i la *curtosi*, com els de la taula 3B.4, ja que en treballar amb errors absoluts, només tenen sentit si es comparen entre resultats d'una mateixa clusterització (el mateix rang de valors).

3B.6 Conclusions

Amb els resultats obtinguts, es poden extreure les conclusions següents:

- La combinació de l'ús de xarxes SOM i l'algoritme de clusterització K-means és capaç de classificar correctament els patrons de pressions sobre la superfície del cilindre.
- Els moments estadístics de les sèries temporals de pressions són suficients per aportar la informació necessària a les ANN perquè puguin capturar la dinàmica del sistema.
- És possible generar una sèrie temporal de coeficients de pressió, a partir de la seva mitjana i desviació estàndard, emprant com a referència una sèrie temporal mesura en un punt diferent que el del que es genera.

Aquests resultats demostren que és possible el càlcul de càrregues aerodinàmiques en casos en què la quantitat de dades experimentals siguin reduïdes, ja que la metodologia desenvolupada permet generar noves dades a partir de les existents i, d'altra banda, obre la possibilitat de la reducció del nombre de sensors necessaris durant la presa de mesures experimentals.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Capítol 3C. Interpolació de coeficients de pressió sobre teulades de cases prefabricades de baixa alçada

3C.1 Introducció

L'objectiu d'aquesta part del treball és desenvolupar un model de predicció de coeficients de pressió (C_p) sobre teulades de cases prefabricades de baixa alçada.

Es disposa d'una àmplia base de dades composta de conjunts de dades experimentals obtingudes per la Universitat de Western Ontario (Canadà). Les dades experimentals han estat preses en un túnel de vent, utilitzant models a escala de les cases prefabricades. Cada conjunt de dades està formant per sèries temporals de coeficients de pressió mesurats sobre la superfície del model en unes condicions experimentals determinades.

El que es vol aconseguir és realitzar un model d'interpolació d'aquests conjunts de dades experimentals, és a dir, ser capaços d'obtenir un conjunt nou de dades, per a unes condicions experimentals no simulades en el túnel de vent, emprant únicament els conjunts de dades de què ja es disposa.

De les sèries temporals de les quals està compost cada conjunt de dades experimentals, se'n poden extreure els quatre primers moments estadístics, és a dir, la mitjana, la desviació estàndard, l'*skewness* i la curtosi. Aquestes dades són suficients per realitzar estudis sobre càrregues aerodinàmiques i, per tant, faciliten enormement la manipulació de dades, ja que en lloc d'haver de treballar amb milers de dades temporals per a cada sensor, es poden condensar en els quatre moments estadístics. Per tant, un primer model d'interpolació anirà destinat a predir els moments estadístics, principalment els dos primers (la mitjana i la desviació estàndard), ja que són amb els que es basen els càlculs de càrregues aerodinàmiques. Un cop predits els dos moments estadístics, és possible fer una reconstrucció de les sèries temporals, que serà, per tant, la segona part d'aquest treball.

Els models de predicció o interpolació es realitzen amb xarxes neuronals artificials (ANN). En aquest cas, s'usa l'algoritme Backpropagation. El desenvolupament del model consta dels passos següents:

1. Identificació de les variables que tenen importància en el sistema. Perquè una xarxa Backpropagation sigui capaç d'aprendre la dinàmica d'un sistema, necessita relacionar les variables d'entrada amb les de sortida de forma correcta. La selecció de les variables d'entrada, i la seva normalització, és primordial si es vol aconseguir que la xarxa sigui capaç de generalitzar.
2. Selecció dels paràmetres de la xarxa: arquitectura, funcions de transferència...

3. Comprovació de l'eficiència de les xarxes dissenyades.

- a. Comparació dels valors interpolats amb les dades experimentals.
- b. Càlcul de càrregues aerodinàmiques amb els valors interpolats.
- c. Reconstrucció de sèries temporals de pressió a partir dels valors interpolats.

3C.2 Dades experimentals

Les dades experimentals utilitzades en aquest treball provenen dels experiments en túnel de vent realitzats amb models a escala per la Universitat de Western Ontario (UWO), al Boundary Layer Wind Tunnel II. A continuació es mostra una descripció detallada dels models a escala, del túnel de vent, de la presa de dades, així com de la simulació de les condicions de vent.

3C.2.1 Models a escala

Tots els models de les cases estan fets a escala 1:100. Per a la present investigació, s'han emprat dades provinents de 6 models diferents, 4 dels quals tenen un pendent de teulada constant i diferents dimensions de teulada, i els altres dos tenen pendents de teulada diferents i iguals dimensions de teulada. D'aquesta forma es pot estudiar independentment l'efecte del pendent de la teulada i el de les dimensions de la teulada. En la taula següent, s'hi mostren els pendents i les dimensions de les teulades dels 6 models a escala.

Pendent de la teulada	Dimensions de la teulada *
1:12	19,1 m × 12,2 m (62,5' × 40')
1:12	38,1 m × 24,4 m (125' × 80')
1:12	57,2 m × 36,6 m (187,5' × 120')
1:12	76,2 m × 48,8 m (250' × 160')
¼:12	38,1 m × 24,4 m (125' × 80')
3:12	38,1 m × 24,4 m (125' × 80')

Taula 3C.1. Pendent i dimensions de les teulades dels sis models a escala emprats en el túnel de vent.
 *Les dimensions són les equivalents a escala real.

La nomenclatura utilitzada per designar el pendent de la teulada és anglosaxona i fa referència a la relació entre l'alçada de la teulada en el punt més alt i la distància horitzontal entre el punt més alt i el més baix.




Fig. 3C.1. Esquema d'un pendent 3:12 on es mostra que per a cada 12 unitats horitzontals, se'n pugen 3.

Per fer-se una idea del valor que representen aquests pendents, a continuació se'n mostra l'equivalència en graus i en % de desnivell:

$$\frac{1}{4}:12 = 1.19^\circ \approx 2\%$$

$$1:12 = 4.76^\circ \approx 8\%$$

$$3:12 = 26.56^\circ = 25\%$$

L'alçada de tots els models (des de la base del model fins al punt més baix de la teulada) és de 12,19 m (40') i és possible reduir-la per treballar amb diferents alçades. En aquest estudi, es treballa amb dues alçades diferents: 7,32 m (24') i 12,19 m (40').




Fig. 3C.2. Exemple d'un dels models a escala situat al túnel de vent.

3C.2.2 Distribució dels sensors de pressió

Cada model està instrumentat amb sensors de pressió que es distribueixen al llarg de tota la superfície. Per l'abast d'aquest treball, només ens interessen els sensors situats

sobre la teulada, que sumen un total de 335 sensors per a cada model. Els sensors estan distribuïts seguint l'esquema de la figura 3C.3 i situats proporcionalment a les dimensions de la teulada, exceptuant els que estan situats als límits exteriors i els que estan al costat de la carena de la teulada (representada per una línia discontinua), que, en aquest cas, sempre mantenen una distància de 152 mm (equivalent a l'escala real) respecte als límits exteriors o a la carena.




Fig. 3C.3. Esquema de la distribució dels sensors (+) sobre la teulada dels models a escala.




Fig. 3C.4. Imatge real de la distribució dels sensors sobre la teulada dels models a escala.

Es pot observar com la densitat de sensors és variable. Això es deu al fet que *a priori* se sap quines zones són les que presentaran més diversitat de valors de pressió i que corresponen a la part encarada a la direcció del vent (esquerra de la figura), i concretament al quadrant inferior esquerre, anàleg a les direccions de vent amb angles compresos entre els 270° i els 360° , tal com s'explica més endavant. Per aquest motiu, en aquestes zones la densitat de sensors és més elevada.

3C.2.3 Simulació de les condicions de vent

Els experiments s'han dut a terme reproduint unes condicions del terreny aigües amunt corresponents a una àrea agrícola, sense tancats i amb edificacions molt disperses. El valor del coeficient de rugositat (z_0) del terreny emprat és de 0,03 m, concordant amb la tipologia Exposure C (*open country*) descrit a ASCE 7-98 (2002). La simulació de la capa límit sobre el terreny està basada en les característiques del vent descrites per ESDU 82026(1), 83045(2) i 74031(3) (1974, 1982 i 1983).

La zona d'alta velocitat, on es desenvolupa l'estructura de la turbulència, del túnel de vent té una amplada de 3,4 m, un alçada variable entre 1,8 m i 2,7 m i una llargària, fins al centre on es col·loquen els models a escala, de 30 m.




Fig. 3C.5. Imatge del túnel de vent on es veu el model a escala en primer pla, els blocs metàl·lics a continuació i les tres agulles amb la barrera travessera al fons.

La superfície del terra està folrada de blocs metàl·lics controlats pneumàticament i que poden adquirir una alçada de fins a 200 mm, amb l'objectiu d'ajustar la rugositat del terreny, juntament amb unes quantes rosques de cargols (figures 3C.2, 3C.4 i 3C.5), dispersades a una distància de 75 mm entre elles, situades entre els blocs metàl·lics (figura 3C.6) i el model a escala, que ajuden a mantenir la intensitat de la turbulència a

les zones més baixes del túnel. Per aconseguir crear una turbulència que sigui consistent amb l'escala 1:100 dels models, se situen tres agulles de 1,5 m i una barrera travessada de 380 mm d'alt a l'entrada del túnel, tal com es pot veure a la figura 3C.6.




Fig. 3C.6. Imatge dels objectes destinats a crear la turbulència a l'entrada del túnel de vent (vist en direcció aigües amunt).

La velocitat de referència del túnel de vent és de 13,72 m/s (45 ft/s). Aproximadament, la velocitat del vent a uns 10 m d'alçada (alçada mitjana de la base de les teulades) és d'un 64% de la velocitat de referència.

3C.2.4 Obtenció dels conjunts de dades

Les mesures de pressió es realitzen mitjançant un sistema de registre de dades de resposta ràpida en el qual tots els sensors actuen de forma simultània a una freqüència de 500 Hz durant 100 s. Per a cada presa de mostres es produeix un retard màxim de 15/16 de la freqüència emprada, i, per tant, és de $15/16 \times 0,002 \text{ s} = 1,875 \text{ m/s}$. El temps de retard s'ajusta mitjançant una interpolació lineal per a cada cicle de presa de mostres, i aconsegueix la simultaneïtat en la mesura de tots els sensors.

Cada experiment consta de 50.000 mesures per sensor ($500 \text{ Hz} \times 100 \text{ s}$). La relació túnel de vent / escala real de la velocitat del vent és d'1:3, amb la qual, emprant l'equació 3C.1, es determina que a escala real, cada experiment correspon a gairebé 1 hora de simulació a una freqüència de presa de mostres de 15 Hz,

$$\left(\frac{Lf}{V}\right)_{escala} = \left(\frac{Lf}{V}\right)_{real} \quad (3C.1)$$

on L és la dimensió del model; f , la freqüència de presa de mostres, i V , la velocitat del vent.

Les mesures de pressió es guarden en format adimensional, en forma de coeficients de pressió (C_p) referits a la pressió dinàmica a una alçada de referència,

$$C_p = \frac{p - p_\infty}{\frac{1}{2} \rho_\infty V_\infty^2} \quad (3C.2)$$

on p és la pressió en el punt on s'avalua C_p , p_∞ és la pressió al corrent lliure (on el corrent és uniforme i amb nivells baixos de turbulència), ρ_∞ és la densitat de l'aire i V_∞ , la velocitat al corrent lliure de l'aire.

Per obtenir el coeficient de pressió referit a l'alçada mitjana de les teulades (C_{pH}), només cal multiplicar C_p per la relació entre la velocitat del vent al corrent lliure i la velocitat del vent a l'alçada de la teulada.

La base on es col·loca el model a escala és rotatòria, fet que permet variar l'angle d'incidència del vent. En aquest estudi, es treballa amb 19 angles diferents, concretament entre 270° i 360° (seguint l'esquema de la figura 3C.3), amb increments de 5° .

Resumint tot el que s'ha descrit en aquest apartat, es disposa d'un total de 228^* conjunts de dades (6 models \times 2 alçades \times 19 angles de vent), compostos per 50.000 mesures del coeficient de pressió per a cada un dels 335^{**} sensors.

* En realitat, són 226 conjunts de dades, ja que no es disposa dels conjunts corresponents a les dues alçades diferents per al model amb teulada de dimensions $57,2 \text{ m} \times 36,6 \text{ m}$ per a l'angle d'incidència de vent de 360° .

** En dos dels models a escala, hi ha un sensor que no està actiu; per tant, es prenen 334 mesures per instant de temps. Aquests models són el de la teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$ per a un pendent $1:12$ i de la teulada de dimensions $19,1 \text{ m} \times 12,2 \text{ m}$.

3C.3 Desenvolupament dels models d'interpolació

Amb els conjunts de dades descrits en l'anterior secció, es poden desenvolupar dos models diferents, un per a diferents dimensions de teulada i un altre per a diferents pendents de teulada. A continuació es mostren els conjunts de dades emprats per a cada model d'interpolació i s'assigna una lletra a cada model a escala de teulada per facilitar-ne la descripció al llarg dels apartats següents.

Model 1. Diferents dimensions de teulada			
Referència	Dimensions	Pendent	Angle del vent
A	$38,1 \text{ m} \times 24,4 \text{ m}$	1:12	$[270^\circ, 360^\circ]$
B	$19,1 \text{ m} \times 12,2 \text{ m}$	1:12	$[270^\circ, 360^\circ]$
C	$76,2 \text{ m} \times 48,8 \text{ m}$	1:12	$[270^\circ, 360^\circ]$
D	$57,2 \text{ m} \times 36,6 \text{ m}$	1:12	$[270^\circ, 355^\circ]$

Model 2. Diferents pendents de teulada			
Referència	Dimensions	Pendent	Angle del vent
A	38,1 m × 24,4 m	1:12	[270°, 360°]
E	38,1 m × 24,4 m	¼:12	[270°, 360°]
F	38,1 m × 24,4 m	3:12	[270°, 360°]

Taula 3C.2. Característiques dels conjunts de dades experimentals emprades en cada model.

Es pot observar que la teulada A s'utilitza en els dos models, ja que té el pendent que li correspon per al model 1 i les dimensions de teulada que li corresponen per al model 2.

Cada model es desenvolupa per separat. En primer lloc, es presenta la realització del model 1 i, a continuació, basant-nos en els resultats obtinguts, el model 2.

3C.3.1 Model 1. Diferents dimensions de teulada

3C.3.1.1 Selecció de variables

El primer pas per a la realització del model d'interpolació, és identificar quines són les variables que afecten la distribució de pressions sobre la superfície de la teulada. A continuació es mostra un esquema de totes les variables disponibles.




Fig. 3C.7. Esquema de les variables que intervenen en el model 1.

- x = Coordenada espacial del sensor respecte a l'amplada de la teulada.
- y = Coordenada espacial del sensor respecte a la llargària de la teulada.
- z = Coordenada espacial del sensor respecte a l'alçada de la teulada.
- X = Amplada total de la teulada.

Y = Llargària total de la teulada.
 H = Alçada de la base de la teulada.
 α = Angle d'incidència del vent.

El segon pas consisteix en el preprocessament d'aquestes variables. Si s'agafen directament les variables tal com vénen en els conjunts de dades, es poden obtenir resultats no desitjats, tal com es mostrarà més endavant. El preprocessament se centra en les coordenades espacials. Si x i y es normalitzen per a cada conjunt de dades per separat, s'aconsegueix, gràcies al fet que la relació amplada/llargària per a totes les teulades és constant, que tinguin les mateixes dimensions, i facilita així el procés de generalització de l'ANN. En cas de no realitzar aquesta normalització, es donaria el cas que, per exemple, la teulada B seria com una part de la teulada C (figura 3C.8). A més, en cas de no realitzar la normalització, es fa necessari modificar la coordenada y , ja que observant l'eix de coordenades de la figura 3C.7 es pot veure que l'origen de coordenades està en direcció oposada a la zona encarada a la direcció del vent. Així, doncs, es creen tres noves variables per cobrir aquestes possibilitats:

$x_n = x$ normalitzada per a cada set de dades $= x/X$.

$y_n = y$ normalitzada per a cada set de dades $= y/Y$.

$y^* = Y - y$ (així se situa l'origen de coordenades a la zona encarada al vent).

En la figura següent, es mostra de forma gràfica la funció de les noves variables.

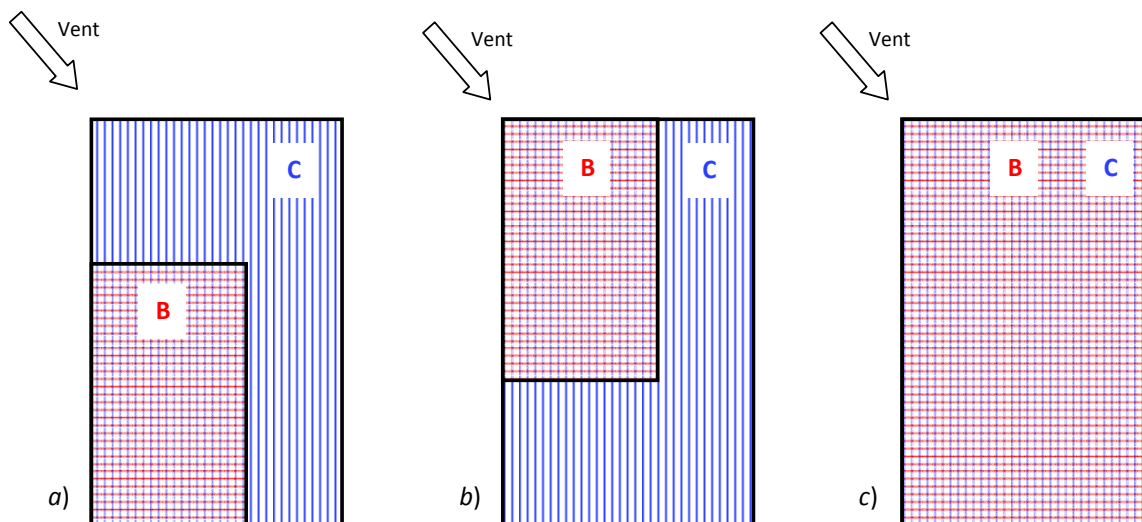


Fig. 3C.8. Exemple gràfic de la funció del preprocessament de les coordenades espacials x i y .

Cada imatge de la Fig.3C.8 mostra de forma gràfica quin seria l'efecte de:

- No realitzar cap preprocessament. S'usa directament les variables x i y . Això suposa que per a l'ANN la teulada B seria una part de la teulada C i que, a més, les coordenades d'origen no concordarien.

b) Es preprocessa la y . S'usa x i y^* . La teulada B continuaria sent una part de C, però aquest cop les coordenades d'origen concordarien.

c) Es normalitza x i y per a cada conjunt de dades. S'usa x_n i y_n . La teulada B i la C tenen les mateixes dimensions per a l'ANN i totes les coordenades espacials concordarien.

El principal problema dels casos a i b és que la teulada presenta pendent i , per tant, hi ha una carena. Si no hi hagués carena, el cas b podria ser tan vàlid com el cas c .

La normalització de les coordenades espacials té una gran repercussió en l'entrenament de l'ANN. En treballs anteriors, Kopp i Chen (2006) van suggerir l'ús de l'alçada H com a paràmetre per normalitzar les variables x i y , ja que les càrregues aerodinàmiques més grans es produeixen per la separació del flux al voltant dels límits de la teulada i aquestes zones es normalitzen bé amb l'alçada H , tal com van demostrar Lin et al. (1995) i Lin i Surry (1998). Aquesta normalització és vàlida quan totes les teulades tenen les mateixes dimensions, però quan es treballa amb teulades de diferents dimensions, com és aquest cas, deixa de ser efectiva. Això es deu al fet que les teulades tenen pendent i , per tant, una carena en la zona central, perpendicular a l'eix Y . La carena té un paper important en el desprendiment i el *reattachment* de la capa límit i , per tant, en el perfil de pressions. Si hi ha diferents dimensions de teulada, la posició de la carena varia. Realitzant la normalització de x i y per a cada conjunt de dades (x_n i y_n), s'aconsegueix mantenir la carena en una posició constant per a tots els conjunts de dades.

Per demostrar que aquesta normalització és la que dóna millors resultats, també es realitzen proves amb les coordenades x i y sense normalitzar. Per tant, en total tenim 10 possibles variables ($X, Y, H, \alpha, x, y, z, x_n, y_n, y^*$). Mitjançant l'algorisme de SOM es realitza un Principal Component Analysis (PCA) de les 10 variables per determinar si hi ha alguna relació lineal entre elles. S'entrena un mapa SOM i es representen les projeccions de cada variable o dimensió dels vectors d'entrenament. Observant la figura 3C.9, es pot veure que hi ha dues parelles de variables que estan clarament relacionades. Són, en primer lloc, l'amplada de teulada X i la llargada de teulada Y . És evident que si la relació X/Y és constant en tots els models a escala, ambdues variables són linealment dependents. La segona parella de variables dependents són l'alçada de la base de la teulada H i la coordenada z . La relació entre ambdues variables també era previsible i es demostra amb l'equació següent:

$$z = \text{abs}[(x - a)p] + H \quad (3C.3)$$

on $a = 0$ si $x \leq X/2$ o $a = X$ si $x > X/2$ i p és el pendent de la teulada.

Per tant, de les deu variables, dues són redundants i tres són variacions de les coordenades x i y . Així, doncs, els vectors d'entrada haurien d'estar compostos per cinc variables com a màxim. Tot i així, en aquest model les dimensions de la teulada tenen molta importància i, per aquest motiu, en algunes de les proves s'empren les variables X

i Y conjuntament per remarcar el seu protagonisme i observar si millora el funcionament de l'ANN.




Fig.3C.9. Representació en SOM de les 10 possibles variables que s'empraran en els vectors d'entrada de l'ANN.

Un cop seleccionades les variables d'entrada, cal seleccionar les de sortida. L'objectiu d'aquest model d'interpolació és predir la mitjana (\bar{C}_p) i la desviació estàndard (\check{C}_p) del coeficient de pressió per a casa sensor. Per tant, aquestes dues variables seran les de sortida de la xarxa. Per facilitar el procés d'aprenentatge i generalització de la xarxa, se'n crea una per a cada variable de sortida. D'aquesta manera hi haurà dues ANN amb una sola variable de sortida per a cadascuna.

3C.3.1.2 Disseny de les xarxes neuronals artificials

Es tracta d'una xarxa del tipus Backpropagation, descrita a fons al capítol 2. A causa del gran volum de dades experimentals de què es disposa, es pot anticipar que la xarxa tindrà un elevat nombre de neurones i, per tant, el seu entrenament requerirà un elevat temps de càlcul computacional. En l'apartat anterior s'ha determinat les variables d'entrada i sortida que utilitzarà cada xarxa per "aprendre" la dinàmica del sistema, és a

dir, quines variables d'entrada són les que determinen la variable de sortida del sistema. Per reduir el temps de càlcul computacional, s'ha optat per començar testant xarxes amb poques neurones amb què escollir quina serà la combinació de variables d'entrada adequada. D'aquesta forma es podran descartar moltes de les combinacions i centrar-nos amb les que millors resultats obtenen. A continuació es mostren les diverses combinacions que s'han testat, així com la nomenclatura que s'usarà d'ara endavant per referir-nos-hi.

Nomenclatura	Variables	Nomenclatura	Variables
A	x, y, z, α	K	x_n, y_n, α, X, Y
B	x, y, α	L	x, y, α, H, X, Y
C	x, y, α, H	M	$x_n, y_n, \alpha, H, X, Y$
D	x_n, y_n, z, α	A0	x, y^*, z, α
E	x_n, y_n, α	B0	x, y^*, α
F	x_n, y_n, α, H	C0	x, y^*, α, H
G	x, y, z, α, X, Y	G0	x, y^*, z, α, X, Y
H	$x_n, y_n, z, \alpha, X, Y$	J0	x, y^*, α, X, Y
I	x_n, y_n, z, α, X	L0	x, y^*, α, H, X, Y
J	x, y, α, X, Y		

Taula 3C.3. Combinació de variables d'entrada emprades i la seva corresponent nomenclatura de referència.

En aquesta taula es pot observar que l'ús d'un 0 darrere de la lletra significa que s'han utilitzat les mateixes variables que per al cas sense el 0, però que en lloc de y o de y_n , s'ha utilitzat y^* .

Un altre mitjà utilitzat per reduir el temps de càlcul ha estat testar primer la xarxa destinada a la predicció de la mitjana del coeficient de pressió (\bar{C}_p) i emprar la combinació de variables amb millors resultats per a la xarxa destinada a la predicció de la desviació estàndard dels coeficients de pressió (\tilde{C}_p).

Arquitectura de la xarxa

Les xarxes tindran tres capes (dues d'ocultes), ja que s'ha demostrat (Haykin, 1994; Hush and Horne, 1993) que aquesta configuració és capaç d'aproximar qualsevol funció no lineal. Les primeres proves es realitzaran amb un màxim de 10 neurones per capa oculta. Més endavant, s'augmentarà fins a 20 neurones per capa i, finalment, fins a 30. En aquest cas, també es designa una nomenclatura específica que s'afegeix a la de la taula 3C.3: $n1$ per al límit de 10 neurones per capa oculta, $n2$ per al de 20 neurones i $n3$ per al de 30 neurones.

Funció de transferència

La funció de transferència és la que s'encarrega de transmetre la informació entre capes. Per a les capes ocultes s'utilitzaran dos tipus diferents de funcions:




Fig. 3C.10. Representació d'una funció de transferència a) logarítmica sigmoïdal i b) tangent sigmoïdal.

Per a la capa de sortida, s'utilitzarà una funció lineal.




Fig. 3C.11. Representació d'una funció de transferència lineal.

Com que per a les capes ocultes es treballa amb dos tipus de funcions de transferència, cal determinar quin tipus s'assigna a cadascuna de les dues capes. En treballs anteriors, Chen et al. (2003b) van emprar la funció tangent sigmoïdal per a les dues capes ocultes quan estimaven \bar{C}_p i la funció logarítmica sigmoïdal quan estimaven \tilde{C}_p . Durant la realització d'aquest treball, s'han provat totes les combinacions possibles de les dues funcions de transferència i s'han obtingut resultats similars en tots els casos, tot i que lleugerament superiors quan s'utilitzava l'opció escollida per Chen et al. Per tant, aquesta és la combinació escollida en els resultats que es presentaran d'ara endavant. Seguint la nomenclatura començada en aquesta secció, se li assignarà un 1 quan s'utilitzi la funció tangent sigmoïdal (i, per tant, en la predicció de \bar{C}_p) i un 2 quan s'utilitzi la funció logarítmica sigmoïdal (i, per tant, en la predicció de \tilde{C}_p).

Per resumir la nomenclatura de la combinació de variables d'entrada, el nombre màxim de neurones a les capes ocultes i les funcions de transferència, a continuació se'n mostren un parell d'exemples:

1An1 = Predicció de \bar{C}_p utilitzant la funció de transferència tangent sigmoïdal en les dues capes ocultes, amb un màxim de 10 neurones en cadascuna d'aquestes capes i la combinació de x, y, z, α com a variables d'entrada.

2Kn3 = Predicció de \tilde{C}_p utilitzant la funció de transferència logarítmica sigmoïdal en les dues capes ocultes, amb un màxim de 30 neurones en cadascuna d'aquestes capes i la combinació de x_n, y_n, α, X, Y com a variables d'entrada.

Altres paràmetres

L'algoritme d'entrenament utilitzat és el del Levenberg-Marquardt, pels motius exposats en el capítol 2.

El nombre d'*epochs* o vegades que s'han presentat el conjunt de dades destinades a l'entrenament és d'un mínim de 25 i d'un màxim de 500, amb increments de 25 per a cada xarxa.

Del total de 150 conjunts de dades experimentals disponibles per al model 1, 32 són reservats per testear la xarxa i la resta s'utilitzen per entrenar-la i validar-la. Els 32 conjunts reservats corresponen als angles d'incidència de vent de 280°, 300°, 320° i 340° per als models a escala A, B, C i D en les seves dues alçades de la base de la teulada possibles (4 angles \times 4 models \times 2 alçades = 32 conjunts de dades).

3C.3.1.3 Primers resultats obtinguts i selecció del conjunt de variables d'entrada

Cada combinació de variables d'entrada és utilitzada per entrenar unes quantes xarxes, i cobrir totes les combinacions possibles de nombre de neurones per capa oculta, fins a un màxim de 10 (*n1*), i de nombre d'*epochs*. Trobar el nombre d'*epochs* adequat és important, ja que si se'n sobrepassa el valor òptim, la xarxa pot acabar "sobrentrenada", i perdre la seva capacitat de generalització.

Cada conjunt de dades experimentals, destinat a l'entrenament, validació o test d'aquestes xarxes, es compon de 335 o 334 vectors (depenent del nombre de sensors sobre la superfície de la teulada del model a escala al qual correspon). Cada vector conté les variables del conjunt d'entrada seleccionat de la taula 3C.3 i la variable de sortida, sigui \bar{C}_p o \tilde{C}_p .

Per avaluar si una xarxa està ben entrenada o no, se li presenta el conjunt de dades destinat a la validació i que no ha estat emprat durant l'entrenament. D'aquesta forma s'obtenen les prediccions de les sortides corresponents; en aquest cas, valors de \bar{C}_p , i se n'avalua el coeficient de correlació de Pearson (*R*) respecte als valors experimentals de \bar{C}_p . Com més alts són els valors de *R*, més gran és la precisió de predicció de la xarxa; el valor de *R* = 1 és el cas de màxima precisió.

A continuació es mostra una taula amb els resultats de predicció, basats en el coeficient de correlació de Pearson (R), per a totes les combinacions de variables d'entrada. A la mateixa taula s'hi adjunta el valor del nombre d'*epochs* i neurones per capa oculta que corresponen a la xarxa que ha obtingut més bon resultat en cada combinació.

Nomenclatura	# neurones per capa oculta	# <i>epochs</i>	R
1An1	9-10	500	0,8596
1Bn1	10-10	500	0,8435
1Cn1	9-9	500	0,8605
1Dn1	10-10	500	0,9690
1En1	10-10	500	0,9202
1Fn1	9-10	500	0,9461
1Gn1	10-10	500	0,9759
1Hn1	9-10	500	0,9806
1In1	10-8	450	0,9799
1Jn1	9-10	500	0,9448
1Kn1	10-10	500	0,9489
1Ln1	10-9	425	0,9746
1Mn1	10-10	500	0,9800
1A0n1	10-8	500	0,9578
1B0n1	9-10	500	0,9223
1C0n1	10-10	400	0,9508
1G0n1	10-10	500	0,9775
1J0n1	10-10	325	0,9459
1L0n1	10-10	450	0,9726

Taula 3C.4. Resultats de la millor predicció de \bar{C}_p per a cada combinació de variables d'entrada per a xarxes amb un màxim de 10 neurones per capa oculta ($n1$).

Per facilitar la comparació entre resultats, a la figura 3C.12 s'hi representa, de forma gràfica, el valor de R per a cada combinació de variables.

A partir de la taula 3C.4 i la figura 3C.12, hom pot veure que hi ha tres combinacions de variables que són les que obtenen millors resultats. Aquestes són:

La I composta per x_n, y_n, z, α, X

La H composta per $x_n, y_n, z, \alpha, X, Y$

La M composta per $x_n, y_n, H, \alpha, X, Y$

Les tres combinacions de variables d'entrada són molt similars i apunten de forma força clara a quines són les variables més importants. Tot i així, es realitza un estudi de cada variable per separat per valorar-ne la influència en els resultats i tenir una base sòlida a

l'hora de fer l'elecció definitiva. L'angle d'incidència del vent (α) no es té en compte en aquest estudi, ja que és evident que és imprescindible i no tindria sentit no utilitzar-lo com a variable en els vectors d'entrenament.




Fig. 3C.12. Coeficient de correlació de Pearson (R) entre la predicció de la xarxa backpropagation i els valors experimentals per a cada combinació de variables d'entrada.

Comencem per la normalització de les coordenades espacials x i y . Se'ns presenten tres possibilitats: x i y / x i y^* / x_n i y_n . En les figures següents, es comparen els resultats de combinacions de variables d'entrada en què només varien aquestes dues variables, diferenciant entre els casos que s'empra la coordenada espacial z i els que no.




Fig. 3C.13. Comparació de l'eficiència de les xarxes en funció del tipus de normalització realitzada a les coordenades espacials x i y per a combinacions de variables d'entrada a) sense emprar la coordenada espacial z i b) emprant-la.

Es pot observar que en la majoria dels casos, i sobretot en les xarxes que obtenen millor valor de R , la normalització x_n, y_n és la que millors resultats proporciona.

En segon lloc, s'avalua la influència d'emprar la coordenada espacial z , distingint entre els tres possibles casos de coordenades espacials x i y descrites en la comparació anterior.

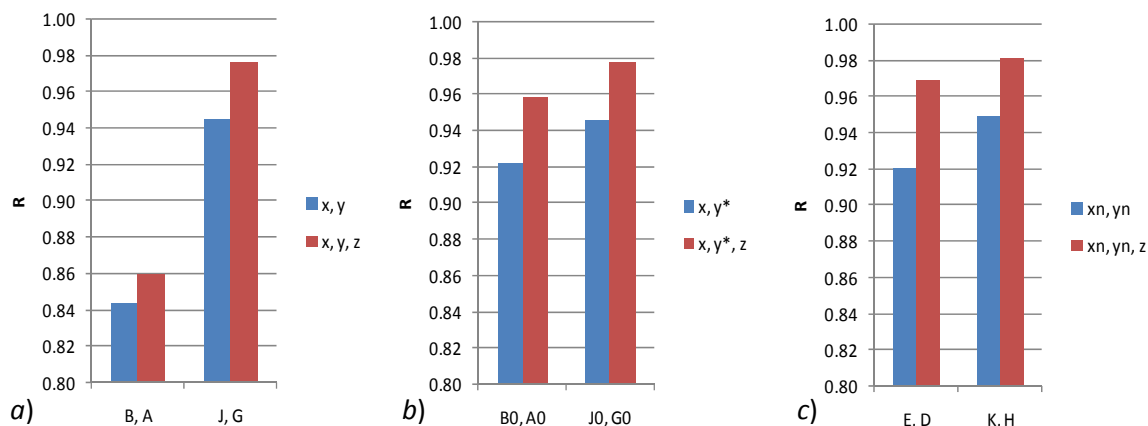


Fig. 3C.14. Comparació de l'eficiència de les xarxes en funció de l'ús o no de la coordenada espacial z per a combinacions de variables d'entrada que empren a) x i y , b) x i y^* i c) x_n, y_n .

Es demostra clarament que l'ús de la coordenada espacial z millora la capacitat d'aprenentatge de la xarxa.

En tercer lloc, s'avalua la influència d'emprar la variable H (alçada de la base de la teulada). Tenint en compte que H i la coordenada espacial z són linealment dependents, com s'ha demostrat amb l'equació 3C.3, s'espera que l'ús de H millori la capacitat d'aprenentatge de la xarxa, tal com s'observa amb la figura 3C.15.




Fig. 3C.15. Comparació de l'eficiència de les xarxes en funció de l'ús o no de l'alçada de la base de la teulada (H) com a variable en el conjunt d'entrades de la xarxa.

En ser z i H linealment dependents, i ambdues variables milloren la capacitat de predicció de la xarxa, cal decidir quina de les dues escollir.




Fig. 3C.16. Comparació de l'eficiència de les xarxes en funció de l'ús de l'alçada de la teulada (H) o de la coordenada espacial z , com a variable en el conjunt d'entrades de la xarxa.

Tot i que els resultats són molt similars, l'ús de la coordenada espacial z , millora lleugerament les prediccions de les xarxes.

Finalment, només queda comprovar l'eficàcia de l'ús de les dimensions de les teulades (X i Y) com a variables d'entrada a les xarxes.




Fig. 3C.17. Comparació de l'eficiència de les xarxes en funció de l'ús o no de les dimensions de teulada (X i Y) com a variables en el conjunt d'entrades de la xarxa.

Observant la figura 3C.17, és evident que l'ús de les dimensions de teulada (X i Y) en el conjunt de variables d'entrada a les xarxes, en millora en rendiment. Cal recordar que s'havia dit que les dues variables són linealment dependents, però que l'ús de les dues al mateix temps remarcava la diferència en les dimensions de les teulades dels quatre models a escala emprats en aquest model d'interpolació. Amb la normalització de les coordenades espaials x i y (x_n i y_n), per a l'ANN totes les teulades tenen les mateixes

dimensions (figura 3C.8c) i l'ús de les dues dimensions de teulada al mateix temps ajuda a la xarxa a discernir entre els quatre models de teulada diferents. Aquest fet es pot observar amb els resultats presentats a la taula 3C.4, on el resultat per a la combinació de dades $H(x_n, y_n, z, \alpha, X, Y)$ obté un valor de R lleugerament superior a l'obtingut per la combinació $I(x_n, y_n, z, \alpha, X)$.

Resumint l'estudi realitzat sobre la influència de les variables del conjunt d'entrada a les xarxes, podem dir que:

- La normalització de les coordenades espacials d'entrada, en la forma de x_n, y_n , és la que funciona millor.
- L'ús de la variable espacial z o de l'alçada de la base de la teulada (H) milloren l'aprenentatge de la xarxa, i la primera és lleugerament més eficient.
- L'ús conjunt de les dimensions de teulada X i Y afavoreixen el correcte entrenament de la xarxa, comparat amb el cas de no utilitzar-les i també amb el cas de només utilitzar una de les dimensions (X o Y).

Per tant, la combinació de variables d'entrada hauria d'estar composta per: x_n, y_n, z, X i Y . Aquesta combinació, junt amb l'angle d'incidència del vent, concorda amb la que ha obtingut millors resultats, que és la combinació H (taula 3C.3).

Ara cal comprovar si aquesta combinació de variables d'entrada també serveix per a la xarxa destinada a predir la desviació estàndard del coeficient de pressió (\tilde{C}_p). Es testen les tres combinacions que han obtingut millors resultats per a la xarxa destinada a la predicció de (\tilde{C}_p) i s'obtenen els resultats següents:

Nomenclatura	# neurones per capa oculta	# epochs	R
2Mn1	10-10	500	0,9778
2Hn1	10-10	450	0,9787
2In1	10-9	500	0,9768

Taula 3C.5. Resultats de la millor predicció de \tilde{C}_p per a cada combinació de variables d'entrada per a xarxes amb un màxim de 10 neurones per capa oculta ($n1$).

Igual que per a l'ANN destinada a la predicció de la mitjana del coeficients de pressió (\bar{C}_p), la combinació de variables d'entrada H és la que funciona millor.

En els resultats presentats per a totes les xarxes (taules 3C.4 i 3C.5), es pot veure com el nombre òptim de neurones per capa oculta i d'*epochs* correspon al valor màxim permès durant l'entrenament de les xarxes. Aquest fet indica que la xarxa es queda petita i necessita més neurones per capa oculta; per tant, s'amplia fins a 20 ($n2$) el nombre màxim de neurones per capa oculta i es tornen a entrenar les ANN, aquest cop únicament per a les combinacions de variables d'entrada M i H en el cas de predir \bar{C}_p , i

la combinació H en el cas de \tilde{C}_p (un cop comprovat que per a \bar{C}_p la combinació H tornava a ser la millor).

Nomenclatura	# neurones per capa oculta	# epochs	R
1Mn2	20-20	475	0,9902
1Hn2	20-20	450	0,9907
2Hn2	18-20	425	0,9914

Taula 3C.6. Resultats de la millor predicció de \bar{C}_p i \tilde{C}_p per a cada combinació de variables d'entrada per a xarxes amb un màxim de 20 neurones per capa oculta ($n2$).

De nou, la combinació H és la que funciona millor. Es pot veure com augmentant el nombre màxim de neurones per capa oculta els resultats milloren significativament, però novament la xarxa es queda petita en necessitar totes les neurones disponibles per obtenir el millor resultat.

3C.3.1.4 Característiques finals de les ANN emprades per al model d'interpolació

Ampliant fins a 30 el nombre màxim de neurones per capa oculta ($n3$), s'aconsegueix trobar la configuració òptima de les dues xarxes destinades a la predicció de la mitjana (\bar{C}_p) i la desviació estàndard (\tilde{C}_p) dels coeficients de pressió. Les xarxes actuen com a funció que relaciona el conjunt de variables d'entrada seleccionat en l'apartat previ i la \bar{C}_p i \tilde{C}_p .

$$\bar{C}_p = f_1(x_n, y_n, z, \alpha, X, Y) \tag{3C.5}$$

$$\tilde{C}_p = f_2(x_n, y_n, z, \alpha, X, Y) \tag{3C.6}$$

Xarxa destinada a la predicció de la mitjana dels coeficients de pressió de cada sensor sobre la superfície de les teulades:

Arquitectura	6-21-30-1
Entrades	$x_n, y_n, z, \alpha, X, Y$
Sortida	\bar{C}_p
Funcions de transferència	Tangent sigmoïdal per a les capes ocultes Lineal per a la capa de sortida
Algoritme d'entrenament	Levenberg-Marquardt
Epochs	450
Eficiència de la xarxa (R)	0,9935

Taula 3C.7 Paràmetres de la xarxa Backpropagation destinada a la predicció de \bar{C}_p per al model 1.




Fig. 3C.18. Representació gràfica de la xarxa descrita a la taula 3C.7.

Xarxa destinada a la predicció de la desviació estàndard dels coeficients de pressió de cada sensor sobre la superfície de les teulades:

Arquitectura	6-26-25-1
Entrades	$x_n, y_n, z, \alpha, X, Y$
Sortida	\tilde{C}_p
Funcions de transferència	Logarítmica sigmoïdal per a les capes ocultes Lineal per a la capa de sortida
Algorisme d'entrenament	Levenberg-Marquardt
Epochs	450
Eficiència de la xarxa (R)	0,9944

Taula 3C.8 Paràmetres de la xarxa Backpropagation destinada a la predicció de \tilde{C}_p per al model 1.




Fig. 3C.19. Representació gràfica de la xarxa descrita a la taula 3C.8.

3C.3.1.5 Comprovació de l'eficàcia del model

Un cop dissenyades i entrenades les ANN, es procedeix a avaluar-ne l'eficàcia emprant els conjunts de dades destinats a aquesta funció. Com ja s'ha comentat anteriorment, un total de 32 conjunts de dades han estat reservats i, per tant, no utilitzats durant l'entrenament de les xarxes.

Distingirem entre dos sistemes d'avaluació de l'eficàcia del model. Un primer sistema consisteix a comparar els valors obtinguts, la mitjana (\bar{C}_p) i la desviació estàndard (\tilde{C}_p) dels coeficients de pressió amb les ANN i els valors experimentals obtinguts al túnel de vent. Un segon sistema consisteix a reconstruir les sèries temporals dels coeficients de pressió (C_p), a partir dels valors obtinguts de la mitjana (\bar{C}_p) i la desviació estàndard (\tilde{C}_p) dels coeficients de pressió amb les ANN, i comparar-les amb les mesures al túnel de vent.

Comencem, doncs, amb el primer sistema d'avaluació, del qual podem distingir també dues parts:

- Error dels valors de \bar{C}_p i \tilde{C}_p obtinguts per a cada sensor i conjunt de dades.
- Càlcul de càrregues aerodinàmiques a partir dels valors de \bar{C}_p i \tilde{C}_p .

Depenent de la zona en què es trobi un sensor, les ANN tindran més dificultats de predir-ne els valors. Com ja s'ha comentat abans, la part de la teulada encarada al vent, i que correspon a la zona amb més densitat de sensors, és on hi ha més riquesa en la variació de valors de C_p . Així, doncs, se selecciona el sensor situat just a la cantonada on incideix el vent (figura 3C.20) per avaluar la capacitat de les ANN per predir els valors de \bar{C}_p i \tilde{C}_p per a un sensor concret. Si els resultats són bons per al sensor situat a la zona més conflictiva de la teulada, es pot deduir que per a la resta de sensors també ho seran. Aquest sensor, junt amb 119 sensors més, conforma l'anomenada *corner bay* (figura 3C.20), que cobreix la zona on es generen els remolins en desprendre's la capa límit, i, per tant, la més important per predir correctament. Per avaluar l'eficiència de les ANN en aquesta zona, es calcula el RMSE (*root mean square error*) entre els valors estimats i els experimentals de \bar{C}_p i \tilde{C}_p per als 120 sensors.

$$RMSE(\%) = 100 * \sqrt{\frac{1}{N} \sum_{i=1}^N (C_{p_{i,est}} - C_{p_{i,exp}})^2} \quad (3C.7)$$




Fig. 3C.20. Representació de la posició del sensor situat a la cantonada de la teulada (requadre negre petit) i de la *corner bay* (requadre negre gran).

En la següent taula es mostren els resultats obtinguts en la predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada, per a cada un dels 32 conjunts de dades emprats en la comprovació de l'eficiència de les ANN, així com de l'RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors que componen la *corner bay*.

Model Teulada	H (m)	α	\bar{C}_p				\tilde{C}_p			
			Sensor cantonada			RMSE (%)	Sensor cantonada			RMSE (%)
			Experim.	ANN	Error (%)		Experim.	ANN	Error (%)	
A	7,32	280°	-0,767	-0,694	-9,5	1,2	0,294	0,278	-5,3	0,6
		300°	-0,749	-0,662	-11,7	2,1	0,309	0,318	3,1	0,9
		320°	-0,539	-0,485	-10,1	2,0	0,213	0,212	-0,6	0,7
		340°	-0,758	-0,831	9,7	1,9	0,301	0,278	-7,7	0,8
	12,19	280°	-0,937	-0,849	-9,4	2,0	0,369	0,323	-12,4	0,9
		300°	-1,061	-1,000	-5,8	2,0	0,412	0,413	0,2	1,0
		320°	-0,823	-0,778	-5,5	2,0	0,293	0,284	-3,0	1,2
		340°	-1,023	-1,012	-1,1	3,0	0,387	0,383	-1,0	1,3

B	7,32	280°	-0,631	-0,601	-4,9	1,4	0,240	0,251	4,5	0,7
		300°	-0,584	-0,668	14,4	6,2	0,254	0,232	-8,7	1,2
		320°	-0,429	-0,447	4,2	5,2	0,216	0,230	6,5	1,0
		340°	-0,763	-0,718	-5,8	2,5	0,331	0,325	-1,9	1,2
	12,19	280°	-0,593	-0,637	7,4	2,7	0,258	0,274	6,2	1,3
		300°	-0,720	-0,776	7,7	2,7	0,305	0,316	3,7	1,5
		320°	-0,656	-0,628	-4,2	3,2	0,265	0,247	-6,6	1,4
		340°	-0,801	-0,802	0,1	2,9	0,363	0,378	4,2	1,8

C	7,32	280°	-0,690	-0,702	1,6	1,7	0,293	0,281	-4,1	0,6
		300°	-0,596	-0,555	-6,9	1,6	0,314	0,301	-4,2	0,7
		320°	-0,515	-0,519	0,7	1,7	0,288	0,245	-14,7	0,8
		340°	-0,846	-0,851	0,5	2,0	0,333	0,354	6,2	0,7
	12,19	280°	-0,998	-0,989	-0,9	1,9	0,387	0,388	0,1	0,8
		300°	-0,913	-0,980	7,4	2,6	0,414	0,420	1,6	1,1
		320°	-0,801	-0,833	4,0	2,7	0,357	0,347	-2,8	1,2
		340°	-1,168	-1,097	-6,1	1,9	0,419	0,439	4,6	0,9

D	7,32	280°	-0,750	-0,717	-4,5	1,4	0,295	0,286	-3,1	0,6
		300°	-0,579	-0,608	5,0	1,2	0,304	0,316	3,8	0,7
		320°	-0,548	-0,527	-3,8	2,0	0,334	0,330	-1,2	0,8
		340°	-0,929	-0,908	-2,2	2,1	0,382	0,408	6,8	0,6
	12,19	280°	-1,014	-0,962	-5,1	2,0	0,379	0,384	1,3	0,9
		300°	-0,935	-1,042	11,4	2,2	0,402	0,412	2,6	1,2
		320°	-0,855	-0,900	5,3	3,1	0,443	0,438	-1,2	1,2
		340°	-1,187	-1,152	-2,9	2,4	0,500	0,505	1,0	0,9

Error mitjà			5,6	2,4		4,2	1,0
-------------	--	--	-----	-----	--	-----	-----

Taula 3C.9 Error de predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada i RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la *corner bay*.

L'error relatiu mitjà de la predicció de la mitjana del coeficient de pressió (\bar{C}_p), per al sensor de la cantonada dels 32 conjunts de dades, que comprenen els models a escala A, B, C i D, per a les dues alçades de la base de teulada possibles i els 19 angles d'incidència del vent, compresos entre els 270° i els 360°, és del 5,6%, amb un error relatiu màxim del 14,5%. Pel que fa a l'error relatiu mitjà de la desviació estàndard del coeficient de pressió (\tilde{C}_p), és del 4,2%, amb un error relatiu màxim del -14,7%. L'RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la *corner bay* és del 2,4%, amb un valor màxim del 6,2% per al primer i de l'1,0% amb un valor màxim d'1,8% per al segon.

Les prediccions per als sensors de la *corner bay* són molt bones, com es reflecteix en els resultats de la taula 3C.9. Per tenir una visió global de la precisió de les prediccions en tota la superfície de les 32 teulades dels models a escala, a continuació es mostren els perfils de \bar{C}_p i \tilde{C}_p estimats i experimentals d'unes quantes teulades, per poder-los comparar visualment.




Fig. 3C.21.1. Distribució de \bar{C}_p sobre una teulada de dimensions $19,1 \text{ m} \times 12,9 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$ i angle d'incidència del vent de 280° a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.






Fig. 3C.21.2. Distribució de \bar{C}_p sobre una teulada de dimensions $19,1 \text{ m} \times 12,9 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$ i angle d'incidència del vent de 280° a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.






Fig. 3C.23.1. Distribució de \bar{C}_p sobre una teulada de dimensions $76,2 \text{ m} \times 48,8 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$ i angle d'incidència del vent de 320° a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.






Fig. 3C.23.2. Distribució de \bar{C}_p sobre una teulada de dimensions $76,2 \text{ m} \times 48,8 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$ i angle d'incidència del vent de 320° a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.



Observant les figures 3C.21-3C.24, es pot veure com les distribucions de les dades estimades tant per \bar{C}_p com per \tilde{C}_p concorden perfectament amb els valors obtinguts al túnel de vent. Aquestes figures corresponen únicament a quatre conjunts de dades, dels trenta-dos estimats, que representen els quatre models a escala de teulada, les dues alçades de base de teulada i els quatre angles d'incidència de vent no emprats en l'entrenament de les ANN. Es pot afirmar que la resta de conjunts han estat predits amb la mateixa eficiència, tal com es pot deduir dels resultats presentats a la taula 3C.9.

La segona part d'aquest primer sistema d'avaluació de l'eficàcia de les ANN és l'aplicació en el càlcul de càrregues aerodinàmiques. Un terme que s'empra en aquest càlcul és l'anomenada *força de sustentació*, que serveix per calcular la força ascendent o descendent a què es veu sotmesa la superfície de la teulada a causa de les diferències de pressió generades pel vent.

$$\bar{F}_s = \frac{1}{A} \sum_{i=1}^N [\bar{C}_{pi} \Delta A_i] \quad [3C.8]$$

Es calcula el valor de \bar{F}_s per a la *corner bay* emprant els valors de \bar{C}_p obtinguts per l'ANN, d'una banda, i els valors experimentals, de l'altra. En la taula següent, s'hi presenten els valors obtinguts i l'error relatiu per a cada conjunt de dades:

Model Teulada	H (m)	α	\bar{F}_s corner bay		
			Experim.	ANN	Error (%)
A	7,32	280°	-0,238	-0,234	-1,7
		300°	-0,223	-0,226	1,3
		320°	-0,260	-0,259	-0,2
		340°	-0,311	-0,310	-0,5
	12,19	280°	-0,334	-0,340	1,6
		300°	-0,335	-0,327	-2,4
		320°	-0,382	-0,385	0,6
		340°	-0,421	-0,433	3,0

B	7,32	280°	-0,293	-0,293	-0,2
		300°	-0,344	-0,287	-16,4
		320°	-0,297	-0,338	13,8
		340°	-0,386	-0,383	-0,7
	12,19	280°	-0,416	-0,429	3,2
		300°	-0,378	-0,378	0,0
		320°	-0,428	-0,430	0,5
		340°	-0,472	-0,483	2,3

C	7,32	280°	-0,150	-0,150	0,2
		300°	-0,150	-0,154	2,5
		320°	-0,183	-0,189	3,0
		340°	-0,226	-0,236	4,1
	12,19	280°	-0,246	-0,252	2,5
		300°	-0,232	-0,247	6,3
		320°	-0,282	-0,291	3,3
		340°	-0,367	-0,355	-3,4

D	7,32	280°	-0,191	-0,187	-2,1
		300°	-0,182	-0,181	-0,4
		320°	-0,219	-0,222	1,3
		340°	-0,270	-0,280	4,0
	12,19	280°	-0,291	-0,291	0,1
		300°	-0,290	-0,288	-0,8
		320°	-0,332	-0,345	4,0
		340°	-0,394	-0,398	0,9

Error mitjà					2,8
-------------	--	--	--	--	-----

Taula 3C.10 Error en la predicció de la força de sustentació \bar{F}_s sobre la superfície de la *corner bay* per a cadascun dels 32 conjunts de dades no emprats en l'entrenament de l'ANN.

L'error mitjà de predicció de la força de sustentació \bar{F}_s sobre la superfície de la *corner bay* és de només el 2,8%, però en dos dels trenta-dos conjunts de dades, aquest error és molt més elevat. Concretament per al model a escala de teulada B (19,1 m × 12,2 m) amb alçada de la base de la teulada de 7,32 m i angle d'incidència del vent de 300° i 320°, on l'error és del -16,4% i del 13,8%, respectivament. Com que les ANN generalitzen el comportament global d'un sistema, és estrany que només dues de les prediccions presentin errors tan grans. Fixant-se amb la taula 3C.9, també es pot veure com la predicció de \bar{C}_p per al sensor de la cantonada d'un d'aquests dos conjunts de dades presenta un error molt per sobre de la mitjana. Per tant, es pot suposar que hi ha algun problema amb les dades experimentals d'aquests dos conjunts de dades. A continuació, es representa gràficament la força de sustentació, calculada a partir de les dades experimentals del túnel de vent, per a tots els conjunts de dades amb alçada de la base de la teulada igual a 7,32 m, és a dir, per a tots els models de teulada a escala i angles d'incidència del vent.




Fig. 3C.25. Força de sustentació a la *corner bay*, calculada amb dades experimentals del túnel de vent, per a tots els models a escala i angles d'incidència del vent per a una alçada de la base de la teulada de 7,32 m.

Efectivament, es pot veure com justament aquests dos conjunts de dades (model a escala B i angles d'incidència del vent de 300° i 320°) no segueixen la tendència de la resta de conjunts de dades. Com hem dit, les ANN aprenen un comportament generalitzat del sistema i, per tant, no són capaces de predir correctament comportaments fora de la norma. Amb una creu (×), a la figura 3C.25 s'ha marcat quin és el valor predit per l'ANN en aquests dos casos i hom pot observar que aquests sí que segueixen la tendència i que en allunyar-se dels valors experimentals provoquen l'augment de l'error de predicció. No s'ha pogut determinar per què aquests dos conjunts de dades experimentals no segueixen la tendència de la resta, però no és descabdellat suposar que presenten algun tipus d'error, sigui durant la presa de mostres, la manipulació d'aquestes o en l'emmagatzemament. Per tant, si no tenim en compte aquests dos conjunts de dades, l'error relatiu màxim de predicció de la força de sustentació sobre la superfície de la *corner bay* ha estat del 6,3% amb un valor mitjà per als trenta conjunts de dades restants de l'1,9%.

Els resultats mostrats fins ara demostren que el model és capaç d'interpol·lar, de forma precisa, entre les diverses direccions de vent i alçades de teulada per als quatre tipus de dimensions de teulada (models a escala A, B, C i D). Seria molt interessant poder comprovar si el model d'interpolació és capaç de predir, de forma correcta, els coeficients de pressió per a teulades de dimensions diferents de les quatre emprades durant l'entrenament de les ANN. Com que no es disposa de dades experimentals provinents de models a escala de dimensions de teulada diferents de les ja descrites, l'única opció que s'ha trobat per poder avaluar de forma aproximada si el model pot predir els coeficients de pressió per a noves dimensions de teulada és la de calcular la força de sustentació de la *corner bay*, de l'hipotètic nou cas, i comprovar si segueix la

tendència esperada, comparant-la amb la de les quatre teulades de les quals sí que es tenen dades experimentals.

Es generen nous conjunts de dades, emprant les ANN del model 1, per a tres noves dimensions de teulada, que es troben dins del rang de dimensions dels quatre tipus de teulades utilitzades durant l'entrenament de les xarxes. Seguint la nomenclatura emprada en la secció 3C.3, els nous conjunts de dades tenen les característiques següents:

Noves dimensions de teulada			
Referència	Dimensions	Pendent	Angle del vent
G	28,6 m × 18,3 m	1:12	[270°, 360°]
H	47,6 m × 30,5 m	1:12	[270°, 360°]
I	66,7 m × 42,7 m	1:12	[270°, 360°]

Taula 3C.11. Característiques dels nous conjunts de dades generades pel model 1.

Si hom compara les dimensions de les teulades *G*, *H* i *I* amb les de les teulades *A*, *B*, *C* i *D* (taula 3C.3), podrà veure com les dimensions de la teulada *G* són un terme mitjà de les teulades *A* i *B*, les de la teulada *H* ho són de les teulades *A* i *C* i, finalment, les de la teulada *I* són un terme mitjà entre les teulades *C* i *D*.




Fig. 3C.26. Força de sustentació a la *corner bay*, calculada amb les dades experimentals dels models de teulada *A*, *B*, *C* i *D* i les dades generades per les ANN per als models *G*, *H* i *I* per a tots els angles d'incidència del vent i una alçada de la base de la teulada de 7,32 m.

A la figura 3C.26, s'hi representa la força de sustentació, per a cada direcció de vent i una alçada de base de teulada de 7,32 m, de les tres noves dimensions de teulada (línia discontinua) i de les quatre dimensions de teulada de les quals es tenen dades experimentals (línia contínua). Com es pot observar, les línies discontinües segueixen el comportament de les contínues i la seva posició s'adequa a la que hom pot esperar si es té en compte la relació de dimensions que existeix entre elles.

Amb els resultats de la figura 3C.26, es demostra que el model d'interpolació funciona bé a l'hora de predir les càrregues aerodinàmiques que sustentarà qualsevol teulada dins del rang de les variables emprades durant l'entrenament de les ANN. Aquests resultats mostren que la predicció dels coeficients de pressió a la *corner bay* són correctes, si més no, de forma global. Per poder veure si la predicció punt a punt és acurada, caldria representar la distribució dels coeficients de pressió sobre tota la superfície de les teulades. En no disposar de les dades experimentals corresponents per a cada nova teulada estimada, es representen les dades predites pel model i es comparen amb les dades experimentals dels dos tipus de teulades més pròxims (una de dimensions inferiors i una de dimensions superiors). D'aquesta forma es pot veure si la distribució dels coeficients de pressió segueix la tendència que caldria esperar.




Fig. 3C.27.1. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 270° , alçada de la base de la teulada de 7,32 m i unes dimensions de a) $19,1 \text{ m} \times 12,9 \text{ m}$ (dades experimentals), b) $28,6 \text{ m} \times 18,3 \text{ m}$ (dades estimades) i c) $38,1 \text{ m} \times 24,2 \text{ m}$ (dades experimentals).




Fig. 3C.27.2. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 295° , alçada de la base de la teulada de 12,19 m i unes dimensions de *a*) 38,1 m \times 24,2 m (dades experimentals), *b*) 47,6 m \times 30,5 m (dades estimades) i *c*) 57,2 m \times 36,6 m (dades experimentals).




Fig. 3C.27.3. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 315° , alçada de la base de la teulada de 7,32 m i unes dimensions de *a*) 57,2 m \times 36,6 m (dades experimentals), *b*) 66,7 m \times 42,7 m (dades estimades) i *c*) 76,2 m \times 48,8 m (dades experimentals).




Fig. 3C.27.4. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 335° , alçada de la base de la teulada de 7,32 m i unes dimensions de a) 38,1 m \times 24,2 m (dades experimentals), b) 47,6 m \times 30,5 m (dades estimades) i c) 57,2 m \times 36,6 m (dades experimentals).




Fig. 3C.27.5. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 360° , alçada de la base de la teulada de 12,19 m i unes dimensions de a) 19,1 m \times 12,9 m (dades experimentals), b) 28,6 m \times 18,3 m (dades estimades) i c) 38,1 m \times 24,2 m (dades experimentals).

Les figures 3C27.1b-5b mostren la distribució de la mitjana dels coeficients de pressió, per a una selecció dels conjunts de dades estimats per a les tres noves dimensions de teulada. Cadascuna d'aquestes figures s'acompanya per la corresponent distribució de dades experimentals provinents de conjunts de dades amb diferents dimensions de teulada, però igual direcció de vent i alçada de la base de teulada (Figs. 3C27.1a,c-5a,c). En tots els casos es pot veure com les dades estimades presenten una distribució molt similar a les experimentals i al mateix s'aprecia una tendència en l'evolució de les distribucions, començant per la teulada de dimensions inferiors fins a la de dimensions superiors (dades experimentals), passant per la teulada de dimensions intermitges (dades estimades).

Pel que fa a la predicció de la desviació estàndard dels coeficients de pressió, l'única manera de comprovar si són estimats de forma correcta és mitjançant la distribució sobre la teulada, ja que a partir de dades de \tilde{C}_p no és possible calcular la desviació estàndard de la força de sustentació de la *corner bay*, i, per tant, compararla amb la de les teulades de les quals sí que es tenen dades experimentals. Així, doncs, de forma anàloga a la realitzada per a \bar{C}_p (figures 3C27.1-5), es representen les distribucions de \tilde{C}_p per a un conjunt de dades de cadascuna de les tres noves teulades estimades (figures 3C28.1-3).




Fig. 3C.28.1. Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 285° , alçada de la base de la teulada de 12,19 m i unes dimensions de a) 19,1 m \times 12,9 m (dades experimentals), b) 28,6 m \times 18,3 m (dades estimades) i c) 38,1 m \times 24,2 m (dades experimentals).




Fig. 3C.28.2. Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 310° , alçada de la base de la teulada de 7,32 m i unes dimensions de *a*) $38,1 \text{ m} \times 24,2 \text{ m}$ (dades experimentals), *b*) $47,6 \text{ m} \times 30,5 \text{ m}$ (dades estimades) i *c*) $57,2 \text{ m} \times 36,6 \text{ m}$ (dades experimentals).




Fig. 3C.28.3. Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 345° , alçada de la base de la teulada de 12,19 m i unes dimensions de *a*) $57,2 \text{ m} \times 36,6 \text{ m}$ (dades experimentals), *b*) $66,7 \text{ m} \times 42,7 \text{ m}$ (dades estimades) i *c*) $76,2 \text{ m} \times 48,8 \text{ m}$ (dades experimentals).

De la mateixa forma que en l'estimació de \bar{C}_p , la distribució de \tilde{C}_p sobre la superfície de les tres noves teulades (un cas o conjunt de dades per a cada nova teulada) és la que

caldría esperar, que demostraria que la xarxa destinada a l'estimació de la desviació estàndard dels coeficients de pressió funciona correctament quan ha de generar conjunts de dades per a teulades de dimensions no emprades durant el seu entrenament.

El segon sistema d'avaluació consisteix, com ja s'ha descrit abans, a reconstruir les sèries temporals dels coeficients de pressió (C_p), a partir dels valors obtinguts de la mitjana (\bar{C}_p) i la desviació estàndard (\tilde{C}_p) dels coeficients de pressió amb les ANN, i comparar-les amb les mesures al túnel de vent.

Actualment, s'estan desenvolupant diversos mètodes per a la simulació de sèries temporals de pressions (Gioffrè et al., 2000, 2001; Gurley et al., 1997; Popescu et al., 1998). N'hi ha que podrien adaptar-se a la interpolació de la base de dades, concretament els treballs de Gioffrè, Gusella i Grigoriu (2000, 2001), els quals necessiten aproximacions de les funcions de probabilitat de distribucions (PDF, de l'anglès *probability distribution functions*) i de la covariància, fet que en complica l'aplicació. El que es busca és un mètode relativament senzill, motiu pel qual s'opta per emprar la metodologia desenvolupada per Chen et al. (2003a). Aquesta metodologia intenta reconstruir les sèries temporals de pressió d'un model a escala a partir d'un altre model tan similar com sigui possible al primer. Es basa amb la descomposició de Reynolds (usada en l'anàlisi de la turbulència), que postula que el valor instantani de la pressió en un punt és igual a la mitjana temporal de pressions en aquest punt més una fluctuació (C'_p).

$$C_p(t) = \bar{C}_p + C'_p(t) \quad (3C.8)$$

Per tant, el que es fa és substituir la mitjana i la desviació estàndard (fluctuació) de la sèrie temporal de referència pels valors obtinguts, amb les ANN, de la sèrie temporal que es vol estimar:

$$C_{pi.est}(t) = \bar{C}_{pi.est} + C'_{pi.ref}(t) \frac{\tilde{C}_{pi.est}}{\tilde{C}_{pi.ref}} \quad (3C.9.1)$$

$$C'_{pi.ref}(t) = C_{pi.ref}(t) - \bar{C}_{pi.ref} \quad (3C.9.2)$$

D'aquesta forma s'aconsegueixen sèries temporals de pressió, per a un model a escala nou, en què cada sensor tindrà un valor de mitjana i desviació estàndard del coeficient de pressió (\bar{C}_p i \tilde{C}_p), estimat per les ANN. A més, com que la sèrie temporal de pressions que s'usa de referència és d'un cas tan similar com sigui possible al que es vol estimar, tindrà una estructura que s'ajustarà força bé a l'experimental. Amb els resultats següents es vol demostrar que es així.

Es reconstrueixen les sèries temporals dels coeficients de pressió per a tots els sensors dels trenta-dos conjunts de dades que no s'han emprats durant l'entrenament de les ANN. A partir d'aquestes sèries, es calcula la força de sustentació sobre la superfície de tota la teulada, però aquest cop per a cada instant de temps, a diferència de com s'ha fet

en l'apartat anterior, en què es calculava directament la mitjana temporal de la força de sustentació (\bar{F}_s).

$$F_s(t) = \frac{1}{A} \sum_{i=1}^N [C_{pi}(t) \Delta A_i] \quad (3C.10)$$

Un cop obtinguda la sèrie temporal de la força de sustentació, se'n calculen els quatre moments estadístics (mitjana, desviació estàndard, *skewness* i curtosi) i es comparen amb els corresponents valors de la sèrie temporal calculada a partir de les dades experimentals.

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,195	0,047	-0,377	3,104
		Estimat	-0,191	0,043	-0,400	3,196
		Error (%)	2,4	7,2	-6,0	-3,0
	300	Experimental	-0,183	0,041	-0,597	3,716
		Estimat	-0,187	0,044	-0,361	2,938
		Error (%)	-2,3	-6,6	39,5	20,9
	320	Experimental	-0,160	0,041	-0,541	3,268
		Estimat	-0,162	0,043	-0,520	3,175
		Error (%)	-0,9	-4,2	4,0	2,9
	340	Experimental	-0,129	0,037	-0,468	3,530
		Estimat	-0,124	0,035	-0,316	3,095
		Error (%)	3,7	5,0	32,4	12,3

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,251	0,062	-0,580	3,220
		Estimat	-0,260	0,061	-0,452	3,195
		Error (%)	-3,9	1,7	22,1	0,8
	300	Experimental	-0,256	0,058	-0,513	2,963
		Estimat	-0,255	0,056	-0,400	3,087
		Error (%)	0,3	2,8	22,1	-4,2
	320	Experimental	-0,229	0,051	-0,449	3,253
		Estimat	-0,226	0,052	-0,325	2,985
		Error (%)	1,0	-2,3	27,6	8,3
	340	Experimental	-0,178	0,045	-0,644	3,442
		Estimat	-0,178	0,044	-0,499	3,291
		Error (%)	0,0	2,2	22,6	4,4

Error mitjà (%)	1,8	4,0	22,0	7,1
-----------------	-----	-----	------	-----

Taula 3C.12.1. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala A (38,1 m × 24,4 m).

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,220	0,065	-0,684	3,581
		Estimat	-0,217	0,067	-0,760	3,768
		Error (%)	1,3	-3,0	-11,1	-5,2
	300	Experimental	-0,274	0,066	-0,415	3,321
		Estimat	-0,217	0,063	-0,540	3,335
		Error (%)	20,7	5,9	-30,0	-0,4
	320	Experimental	-0,162	0,061	-0,419	2,840
		Estimat	-0,200	0,058	-0,520	3,215
		Error (%)	-23,4	5,0	-24,0	-13,2
	340	Experimental	-0,158	0,055	-0,504	3,207
		Estimat	-0,155	0,051	-0,554	3,862
		Error (%)	2,4	7,9	-10,1	-20,4

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,303	0,096	-0,760	3,660
		Estimat	-0,311	0,093	-0,589	3,289
		Error (%)	-2,6	3,8	22,5	10,1
	300	Experimental	-0,280	0,080	-0,670	3,573
		Estimat	-0,278	0,082	-0,578	3,621
		Error (%)	0,5	-1,9	13,8	-1,3
	320	Experimental	-0,248	0,069	-0,470	3,295
		Estimat	-0,250	0,070	-0,520	3,246
		Error (%)	-0,6	-0,9	-10,7	1,5
	340	Experimental	-0,216	0,063	-0,550	3,514
		Estimat	-0,224	0,064	-0,489	3,458
		Error (%)	-3,7	-2,4	11,0	1,6

Error mitjà (%)	6,9	3,8	16,7	6,7
-----------------	-----	-----	------	-----

Taula 3C.12.2. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala B (19,1 m × 12,9 m).

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,135	0,030	-0,328	3,255
		Estimat	-0,135	0,031	-0,299	3,247
		Error (%)	-0,2	-1,5	8,8	0,3
	300	Experimental	-0,131	0,030	-0,507	3,390
		Estimat	-0,133	0,030	-0,205	2,925
		Error (%)	-1,6	0,7	59,7	13,7
	320	Experimental	-0,111	0,029	-0,200	3,004
		Estimat	-0,111	0,028	-0,199	3,285
		Error (%)	-0,4	1,7	0,2	-9,3
	340	Experimental	-0,081	0,026	-0,312	3,221
		Estimat	-0,086	0,025	-0,161	2,981
		Error (%)	-7,0	3,1	48,3	7,4

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,211	0,044	-0,466	3,161
		Estimat	-0,214	0,043	-0,462	3,158
		Error (%)	-1,5	2,5	0,9	0,1
	300	Experimental	-0,188	0,036	-0,422	3,208
		Estimat	-0,202	0,039	-0,314	3,005
		Error (%)	-7,2	-10,1	25,4	6,3
	320	Experimental	-0,161	0,034	-0,262	3,214
		Estimat	-0,168	0,035	-0,313	3,235
		Error (%)	-4,4	-3,5	-19,8	-0,7
	340	Experimental	-0,150	0,030	-0,432	3,358
		Estimat	-0,136	0,029	-0,418	3,336
		Error (%)	9,3	4,4	3,3	0,7

Error mitjà (%)	3,9	3,4	20,8	4,8
-----------------	-----	-----	------	-----

Taula 3C.12.3. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala C (76,2 m × 48,8 m).

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,171	0,038	-0,332	3,010
		Estimat	-0,163	0,039	-0,429	3,242
		Error (%)	4,1	-5,0	-28,9	-7,7
	300	Experimental	-0,156	0,038	-0,394	3,237
		Estimat	-0,159	0,038	-0,533	3,373
		Error (%)	-2,1	0,3	-35,3	-4,2
	320	Experimental	-0,130	0,034	-0,343	3,174
		Estimat	-0,133	0,035	-0,279	3,393
		Error (%)	-2,2	-2,5	18,6	-6,9
	340	Experimental	-0,099	0,032	-0,170	3,145
		Estimat	-0,108	0,030	-0,221	2,935
		Error (%)	-9,5	5,7	-29,9	6,7

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,240	0,052	-0,630	3,415
		Estimat	-0,238	0,051	-0,585	3,317
		Error (%)	0,8	3,7	7,2	2,9
	300	Experimental	-0,227	0,045	-0,289	2,962
		Estimat	-0,230	0,047	-0,440	3,589
		Error (%)	-1,2	-5,2	-52,2	-21,2
	320	Experimental	-0,188	0,044	-0,257	2,883
		Estimat	-0,195	0,044	-0,423	3,157
		Error (%)	-3,7	-0,1	-64,5	-9,5
	340	Experimental	-0,157	0,036	-0,239	2,975
		Estimat	-0,156	0,036	-0,322	2,992
		Error (%)	0,5	-0,6	-34,9	-0,6

Error mitjà (%)	3,0	2,9	33,9	7,5
-----------------	-----	-----	------	-----

Taula 3C.12.4. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala D (57,2 m × 36,6 m).

Observant la taula 3C.12.2, es pot veure com, de nou, els resultats de l'error per a la mitjana de la força de sustentació en el model a escala B (19,1 m × 12,9 m) i angles d'incidència del vent de 300° i 320°, són força superiors a la resta. Si no els tenim en compte, s'obté un error mitjà per als trenta conjunts de dades de només el 2,7% per a la mitjana i del 3,4% per a la desviació estàndard, amb un valor màxim del 9,5% i del 10,1%, respectivament. Pel que als errors en l'*skewness* i la *curtosi*, són força més alts, sobretot en el primer. Això es deu al fet que aquests moments estadístics no s'han tingut en compte en la reconstrucció de les sèries temporals dels coeficients de pressió

(equació 3C.9). Els valors mitjans dels errors per l'*skewness* i la curtosi són del 23,1% per al primer i del 6,5% per al segon, amb valors màxims del 64,5% i del 21,2%, respectivament.

Els conjunts de dades de referència que s'han escollit per a les reconstruccions corresponen, en cada cas, a un conjunt de dades amb les mateixes dimensions de teulada, pendent de teulada i alçada de la base de teulada, amb l'única diferència de l'angle d'incidència del vent, que s'ha buscat que fos tan similar com sigui possible al del conjunt de dades per reconstruir. En el treball de Chen et al. (2003a), s'emprava com a referència conjunts de dades amb el mateix angle d'incidència del vent, pendent de teulada i dimensions, on l'única diferència era l'alçada de la base de la teulada. Aquesta elecció seria la més encertada, ja que la variació de la distribució dels coeficients de pressió sobre les teulades és menor amb el canvi d'alçada de la base de la teulada que amb el de l'angle d'incidència del vent. Però aquesta elecció no ha estat possible, ja que els conjunts de dades en què només variava l'alçada de la base de la teulada són precisament els que s'han reconstruït.

Per acabar, es mostren figures amb l'autoespectre de la sèrie temporal de la força de sustentació (F_s) estimada comparat amb el de la sèrie temporal experimental, per a quatre dels conjunts de dades estimats.




Fig. 3C.29.1. Autoespectre de la força de sustentació sobre una teulada de dimensions $19,1 \text{ m} \times 12,9 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$ i angle d'incidència del vent de 280° .




Fig. 3C.29.2. Autoespectre de la força de sustentació sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$ i angle d'incidència del vent de 300° .




Fig. 3C.29.3. Autoespectre de la força de sustentació sobre una teulada de dimensions $76,2 \text{ m} \times 48,8 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$ i angle d'incidència del vent de 320° .




Fig. 3C.29.4. Autoespectre de la força de sustentació sobre una teulada de dimensions $57,2 \text{ m} \times 36,6 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$ i angle d'incidència del vent de 340° .

Es pot observar com, en els quatre casos, els autoespectres de les sèries temporals estimades són gairebé calcats als experimentals, i es demostra que la desviació estàndard de la força de sustentació és estimada correctament i que el comportament del vent sobre el model de referència és prou similar a l'estimat per compartir autoespectre. Per a la resta de conjunts de dades, s'han obtingut resultats similars.

3C.3.2 Model 2. Diferents pendents de teulada

3C.3.2.1 Selecció de variables

En aquest model, cal afegir-hi una nova variable, que és el pendent de la teulada, però se'n poden eliminar dues, que són l'amplada i la llargària de la teulada (X i Y), ja que, en els conjunts de dades destinades a aquest model, romanen constants. Per tant, es disposa de sis variables:

x = coordenada espacial del sensor respecte a l'amplada de la teulada.

y = coordenada espacial del sensor respecte a la llargària de la teulada.

z = coordenada espacial del sensor respecte a l'alçada de la teulada.

H = alçada de la base de la teulada.

α = angle d'incidència del vent.

p = pendent de la teulada.

Com ja s'ha vist en el model anterior, l'alçada total de la teulada (H) i la coordenada espacial z són linealment dependents, fet pel qual només cal usar-ne una de les dues. Un punt de gran importància en el model 1 era la normalització de les coordenades espacials, de forma que s'aconseguís que la carena de les teulades estigués situada en una posició constant per a tots els conjunts de dades, i facilitar així el procés de generalització de les ANN. En aquest cas, no és necessari, ja que tots els conjunts de dades destinats a aquest model tenen les mateixes dimensions de teulada i, per tant, la carena sempre estarà situada a les mateixes coordenades.

Així, doncs, les variables d'entrada a les ANN es redueixen a un total de sis, on dues són dependents, la qual cosa fa un total de dues possibles combinacions. En el model anterior s'ha vist com amb l'ús de l'alçada de la base de la teulada (H) i la coordenada espacial z s'obtenien resultats similars, tot i que lleugerament millors en el cas de z . Amb vista de poder unificar en un futur els dos models, s'escull z com a variable d'entrada (en proves que no es presentaran en aquest treball, s'ha comprovat que z aporta una lleugera millora en els resultats respecte a H). De nou, l'objectiu d'aquest model d'interpolació és predir la mitjana (\bar{C}_p) i la desviació estàndard (\tilde{C}_p) del coeficient de pressió per a casa sensor. Per tant, aquestes dues variables seran les de sortida de la xarxa. Per facilitar el procés d'aprenentatge i generalització de la xarxa, se'n crea una per a cada variable de sortida. D'aquesta manera hi haurà dues ANN amb una sola variable de sortida per a cadascuna.

3C.3.2.2 Disseny de les xarxes neuronals artificials

La metodologia seguida per al disseny de les dues xarxes és la mateixa que per al model 1 i, per tant, s'obviaran les descripcions detallades ja realitzades anteriorment. Fixades les variables d'entrada i sortida de les ANN, queden definides per les funcions següents:

$$\bar{C}_p = f_1(x, y, z, \alpha, p) \quad (3C.11)$$

$$\tilde{C}_p = f_2(x, y, z, \alpha, p) \quad (3C.12)$$

Les xarxes, del tipus Backpropagation, es componen de dues capes ocultes que tenen com a màxim 30 neurones per capa oculta. Començant per un límit de 10 neurones per capa oculta, s'ha anat augmentant fins a 30, on ja s'han aconseguit resultats prou satisfactoris. Superant el límit de les 30 neurones per capa oculta, el temps de càlcul computacional es torna impracticable (a dia d'avui) i la millora que es podria aconseguir en els resultats és poc significativa.

Les funcions de transferència emprades han estat, de nou, la tangencial sigmoïdal i la logarítmica sigmoïdal per a les capes ocultes, i la lineal per a la capa de sortida. En els resultats que es presenten més endavant, es podrà observar que, aquest cop, la combinació de les funcions de transferència en les capes ocultes no és la mateixa que per a l'anterior model, en el cas de l'ANN destinada a la interpolació de \tilde{C}_p . Aquesta

decisió s'ha pres únicament basada en els resultats obtinguts durant el procés de disseny de les xarxes. És a dir, com ja s'havia fet per al model 1, que es començava entrenant xarxes de dimensions reduïdes, per optimitzar el temps de càlcul computacional, on es combinaven tots els paràmetres possibles (variables d'entrada, funcions de transferència, nombre d'*epochs*...). D'aquesta forma, s'ha trobat que l'ús de la combinació de les dues funcions de transferència sigmoïdals (tangencial i logarítmica) millora l'eficiència de la xarxa destinada a la predicció \bar{C}_p en lloc d'emprar dues funcions logarítmiques sigmoïdals.

L'algoritme d'entrenament utilitzat és el de Levenberg-Marquardt, pels motius exposats en el capítol 2.

El nombre d'*epochs* o vegades que s'ha presentat el conjunt de dades destinades a l'entrenament és d'un mínim de 25 fins a un màxim de 250, amb increments de 25 per a cada xarxa.

Del total de 114 conjunts de dades experimentals disponibles per al model 2, 24 són reservats per testejar la xarxa i la resta s'utilitza per entrenar-la i validar-la. Els 24 conjunts reservats corresponen als angles d'incidència de vent de 280°, 300°, 320° i 340° per als models a escala A, F i E (taula 3C.2) en les dues alçades de la base de la teulada possibles (4 angles × 3 models × 2 alçades = 24 conjunts de dades).

3C.3.2.3 Característiques finals de les ANN emprades per al model d'interpolació

A continuació, es presenten les característiques finals de les dues ANN destinades a la interpolació de conjunts de dades amb variacions en el pendent de la teulada:

Xarxa destinada a la predicció de la mitjana dels coeficients de pressió de cada sensor sobre la superfície de les teulades:

Arquitectura	5-29-27-1
Entrades	x, y, z, α, p
Sortida	\bar{C}_p
Funcions de transferència	Tangent sigmoïdal per a les capes ocultes Lineal per a la capa de sortida
Algoritme d'entrenament	Levenberg-Marquardt
<i>Epochs</i>	250
Eficiència de la xarxa (R)	0,9964

Taula 3C.13 Paràmetres de la xarxa Backpropagation destinada a la predicció de \bar{C}_p per al model 2.




Fig. 3C.30. Representació gràfica de la xarxa descrita a la taula 3C.13.

Xarxa destinada a la predicció de la desviació estàndard dels coeficients de pressió de cada sensor sobre la superfície de les teulades:

Arquitectura	5-28-30-1
Entrades	x, y, z, α, p
Sortida	\tilde{C}_p
Funcions de transferència	Tangent sigmoïdal per a la primera capa oculta Logarítmica sigmoïdal per a la segona capa oculta Lineal per a la capa de sortida
Algoritme d'entrenament	Levenberg-Marquardt
Epochs	250
Eficiència de la xarxa (R)	0,9954

Taula 3C.14. Paràmetres de la xarxa Backpropagation destinada a la predicció de \tilde{C}_p per al model 2.




Fig. 3C.31. Representació gràfica de la xarxa descrita a la taula 3C.14.

3C.3.2.4 Comprovació de l'eficàcia del model

Un cop dissenyades i entrenades les ANN, es procedeix a avaluar-ne l'eficàcia emprant els conjunts de dades destinats a aquesta funció. Com ja s'ha comentat anteriorment, un total de 24 conjunts de dades han estat reservades i, per tant, no utilitzades durant l'entrenament de les xarxes.

El sistema d'avaluació de l'eficàcia del model 2 és el mateix que s'ha realitzat per al model 1. De forma resumida, es diferencia en dues parts:

- Avaluació dels valors de \bar{C}_p i \tilde{C}_p predits:
 - o Error dels valors de \bar{C}_p i \tilde{C}_p obtinguts per a cada sensor i conjunt de dades.
 - o Càlcul de càrregues aerodinàmiques a partir dels valors de \bar{C}_p i \tilde{C}_p .
- Reconstrucció de les sèries temporals dels coeficients de pressió a partir dels valors interpolats de \bar{C}_p i \tilde{C}_p .

En la taula següent es mostren els resultats obtinguts en la predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada (figura 3C.20), per a cada un dels 24 conjunts de dades emprats en la comprovació de l'eficiència de les ANN, així com de l'RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors que componen la *corner bay* (figura 3C.20).

Model Teulada	H (m)	α	\bar{C}_p				\tilde{C}_p			
			Sensor cantonada			RMSE (%)	Sensor cantonada			RMSE (%)
			Experim,	ANN	Error (%)		Experim,	ANN	Error (%)	
A	7,32	280°	-0,767	-0,716	-6,6	1,5	0,294	0,269	-8,6	0,7
		300°	-0,749	-0,747	-0,3	1,7	0,309	0,316	2,5	0,7
		320°	-0,539	-0,541	0,4	1,8	0,213	0,207	-2,8	0,7
		340°	-0,758	-0,773	2,1	1,7	0,301	0,310	2,9	0,9
	12,19	280°	-0,937	-0,962	2,7	1,3	0,369	0,332	-10,1	0,9
		300°	-1,061	-1,031	-2,9	1,9	0,412	0,409	-0,9	0,7
		320°	-0,823	-0,824	0,2	2,1	0,293	0,290	-1,0	1,2
		340°	-1,023	-1,072	4,8	2,2	0,387	0,395	2,0	1,1

E	7,32	280°	-0,721	-0,712	-1,2	1,5	0,289	0,262	-9,2	0,7
		300°	-0,681	-0,700	2,8	1,8	0,319	0,338	6,0	0,7
		320°	-0,551	-0,559	1,5	2,0	0,208	0,223	7,1	0,7
		340°	-0,773	-0,709	-8,2	2,4	0,332	0,316	-4,9	0,7
	12,19	280°	-0,803	-0,876	9,1	2,2	0,334	0,310	-7,3	1,0
		300°	-1,037	-0,966	-6,8	1,9	0,420	0,392	-6,6	0,7
		320°	-0,814	-0,830	2,0	2,4	0,267	0,271	1,5	1,0
		340°	-1,032	-0,985	-4,5	2,5	0,410	0,381	-7,0	1,2

F	7,32	280°	-0,435	-0,452	4,1	1,1	0,176	0,200	13,6	0,7
		300°	-0,360	-0,342	-4,9	1,3	0,210	0,187	-10,8	0,6
		320°	-0,381	-0,408	6,9	1,8	0,288	0,262	-9,2	0,9
		340°	-0,780	-0,784	0,5	2,2	0,322	0,323	0,3	0,9
	12,19	280°	-0,661	-0,681	3,0	1,6	0,251	0,251	-0,1	0,7
		300°	-0,536	-0,526	-1,9	1,9	0,265	0,254	-4,0	0,8
		320°	-0,596	-0,584	-2,0	2,2	0,369	0,337	-8,7	1,2
		340°	-0,987	-0,995	0,7	2,8	0,391	0,390	-0,3	1,4

Error mitjà			3,3	1,9		5,3	0,9
-------------	--	--	-----	-----	--	-----	-----

Taula 3C.15 Error de predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada i RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la *corner bay*.

L'error relatiu mitjà de la predicció de la mitjana del coeficient de pressió (\bar{C}_p), per al sensor de la cantonada dels 24 conjunts de dades, que comprenen els models a escala A, E i F, per a les dues alçades de la base de teulada possibles i els 19 angles d'incidència del vent, compresos entre els 270° i els 360°, és del 3,3%, amb un error relatiu màxim del 9,1%. Pel que fa a l'error relatiu mitjà de la desviació estàndard del coeficient de pressió (\tilde{C}_p), és del 5,3% amb un error relatiu màxim del 13,6%. L'RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la *corner bay* és de l'1,9%, amb un valor màxim del 2,8%, per al primer i del 0,9%, amb un valor màxim d'1,4%, per al segon.

Com en cas del model 1, les prediccions per als sensors de la *corner bay* són molt bones i fins i tot les milloren. A continuació es mostren els perfils de \bar{C}_p i \tilde{C}_p , estimats i experimentals, sobre la superfície de tota la teulada, d'uns quants conjunts de dades, per poder-los comparar visualment i apreciar la gran similitud entre ells.




Fig. 3C.32.1. Distribució de \bar{C}_p sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 280° i pendent de teulada de $1/4:12$ a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.






Fig. 3C.32.2. Distribució de \tilde{C}_p sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 280° i pendent de teulada de $1/4:12$ a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.






Fig. 3C.34.1. Distribució de \bar{C}_p sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$, angle d'incidència del vent de 320° i pendent de teulada de 3:12 a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.




Fig. 3C.34.2. Distribució de \tilde{C}_p sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$, angle d'incidència del vent de 320° i pendent de teulada de 3:12 a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.




Fig. 3C.35.1. Distribució de \bar{C}_p sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 340° i pendent de teulada de 3:12 a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.




Fig. 3C.35.2. Distribució de \tilde{C}_p sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 340° i pendent de teulada de 3:12 a partir de dades a) estimades per l'ANN i b) experimentals provinents del túnel de vent.

Observant les figures 3C.32-3C.35, es pot veure com les distribucions de les dades estimades tant per \bar{C}_p com per \tilde{C}_p concorden perfectament amb els valors obtinguts al túnel de vent. Aquestes figures corresponen únicament a quatre conjunts de dades, dels vint-i-quatre estimats, que representen els tres models a escala de teulada, les dues alçades de base de teulada i els quatre angles d'incidència de vent no emprats en l'entrenament de les ANN. Es pot afirmar que la resta de conjunts han estat predits amb la mateixa eficiència, tal com es pot deduir dels resultats presentats a la taula 3C.15.

La segona part d'aquest primer sistema d'avaluació de l'eficàcia de les ANN és el càlcul de càrregues aerodinàmiques a partir dels valors predits de \bar{C}_p i \tilde{C}_p . En la taula 3C.16 es presenten els valors obtinguts i l'error relatiu per a cada conjunt de dades del valor de \bar{F}_s (mitjana temporal de la força de sustentació sobre una superfície) per a la *corner bay*, emprant els valors de \bar{C}_p obtinguts per l'ANN, d'una banda, i els valors experimentals, de l'altra.

Model Teulada	H (m)	α	\bar{F}_s <i>corner bay</i>		
			Experim.	ANN	Error (%)
A	7,32	280°	-0,238	-0,232	-2,5
		300°	-0,223	-0,226	1,0
		320°	-0,260	-0,260	0,2
		340°	-0,311	-0,310	-0,6
	12,19	280°	-0,334	-0,339	1,3
		300°	-0,335	-0,328	-1,9
		320°	-0,382	-0,381	-0,2
		340°	-0,421	-0,428	1,8

E	7,32	280°	-0,238	-0,240	0,7
		300°	-0,229	-0,236	3,3
		320°	-0,267	-0,267	0,0
		340°	-0,299	-0,304	1,5
	12,19	280°	-0,346	-0,341	-1,4
		300°	-0,331	-0,331	-0,1
		320°	-0,375	-0,383	2,2
		340°	-0,436	-0,435	-0,4

F	7,32	280°	-0,144	-0,148	2,8
		300°	-0,154	-0,152	-1,6
		320°	-0,199	-0,200	0,4
		340°	-0,270	-0,267	-1,2
	12,19	280°	-0,247	-0,249	0,9
		300°	-0,242	-0,241	-0,6
		320°	-0,291	-0,285	-2,0
		340°	-0,393	-0,379	-3,4

Error mitjà				1,3
-------------	--	--	--	-----

Taula 3C.16. Error en la predicció de la força de sustentació \bar{F}_s sobre la superfície de la *corner bay* per a cadascun dels 24 conjunts de dades no emprats en l'entrenament de l'ANN.

L'error relatiu mitjà de predicció de la força de sustentació sobre la superfície de la *corner bay* ha estat de només l'1,3% amb un valor màxim per als vint-i-quatre conjunts de dades del 3,4%.

Amb aquests resultats, es demostra que el model d'interpolació és capaç d'estimar, de forma precisa, la mitjana i la desviació estàndard dels coeficients de pressió, per als conjunts de dades no emprats durant l'entrenament de les xarxes. De la mateixa manera com s'ha fet per al model 1, es procedeix a comprovar la capacitat d'aquest model per generar conjunts de dades on la variable principal, en aquest cas el pendent de la teulada, sigui diferent dels tres pendents emprats durant l'entrenament de les xarxes.

Per tant, es generen nous conjunts de dades, emprant les ANN del model 2, per a tres nous pendents de teulada, que es troben dins del rang de pendents dels tres tipus de teulades utilitzades durant l'entrenament de les xarxes. Seguint la nomenclatura emprada en la secció 3C.3, els nous conjunts de dades tenen les característiques següents:

Nous pendents de teulada			
Referència	Dimensions	Pendent	Angle del vent
J	38,1 m × 24,2 m	2:12	[270°, 360°]
K	38,1 m × 24,2 m	5/2:12	[270°, 360°]
L	38,1 m × 24,2 m	11/4:12	[270°, 360°]

Taula 3C.17. Característiques dels nous conjunts de dades generades pel model 2.

Els nous pendents estan compresos entre els pendents dels models a escala A i F (1:12 i 3:12). L'elecció d'aquest rang es deu al fet que entre els pendents dels models a escala A i E (1:12 i ¼:12) no hi ha gaire variació en les distribucions dels coeficients de pressió sobre les seves teulades, ja que en tractar-se de pendents molt suaus, el seu efecte és mínim. En canvi, a partir del pendent 1:12, l'efecte del pendent és més

pronunciat i, per tant, la interpolació és més complicada. Per aquest motiu es tria aquest interval de pendents, ja que així es posa a prova la capacitat d'interpolació del model.

Tal com s'ha fet per al model 1, per comprovar si els nous conjunts de dades generats són correctes o, si més no, s'ajusten al que hom espera, es compara la tendència de la força de sustentació de la *corner bay*, dels nous conjunts de dades generats, amb l'obtinguda a partir de les dades experimentals disponibles. Al mateix temps, es representa la distribució de la mitjana i la desviació dels coeficients de pressió estimats, i es compara amb les distribucions de les dades experimentals; s'observa si els resultats obtinguts presenten el comportament esperat. Com ja s'ha comentat anteriorment, l'avaluació d'aquests resultats és subjectiva, ja que no es poden aportar resultats numèrics dels errors de predicció, en no tenir dades experimentals amb què comparar les estimacions. Tot i així, amb les figures amb què es treballa, es veu de forma clara quan una predicció pot ésser o no encertada.

Emprant les ANN del model 2, s'han generat 114 nous conjunts de dades (19 angles de vent \times 2 alçades de la base de la teulada \times 3 pendents de teulada) i se n'han calculat les forces de sustentació a la *corner bay*; s'ha obtingut uns resultats no desitjats. La tendència de la força de sustentació, així com les distribucions de \bar{C}_p i \tilde{C}_p sobre les teulades, no són correctes en diversos dels nous conjunts de dades generats per les ANN. S'ha provat de generar conjunts de dades amb pendents més suaus (3/5:12), i s'han obtingut bons resultats. Amb aquest fet es determina que el model 2 només pot interpolat (nous pendents no emprats durant l'entrenament de les ANN) pendents molt suaus, que, com ja s'ha comentat anteriorment, són els més senzills d'estimar. Per trobar el motiu de la incapacitat del model per interpolat pendents superiors a 1:12, cal fixar-nos en el coeficient de correlació (R) obtingut durant l'entrenament de les xarxes. És superior a 0,995, tant per a la xarxa destinada a estimar \bar{C}_p com a la destinada a estimar \tilde{C}_p . Tot i que per al model 1, el valor de R també és molt alt (superior a 0,993), en el cas del model 2, les variacions de les distribucions dels coeficients de pressió, sobre les teulades, són més elevades a mesura que augmenta el pendent de la teulada que per al model 1, on es mantenen força constants dins el domini d'interpolació. És a dir, el model 2 cal que sigui molt més flexible que el model 1, per poder interpolat casos en què la distribució de C_p és força diferent de la majoria de dades emprades durant l'entrenament (2/3 parts de les dades corresponen als pendents 1/4:12 i 1:12, amb perfils de C_p força constants, mentre que només 1/3 corresponen al pendent 3:12). El que es vol dir és que les ANN del model 2 han estat sobreentrenades i, en certa manera, han memoritzat el comportament dels tres pendents emprats durant l'entrenament. Per tant, el model 2 és capaç d'interpolat, de forma precisa, conjunts de dades per a diferents angles de vent i alçada de la base de la teulada per als 3 pendents emprats durant l'entrenament (1/4:12, 1:12 i 3:12), però erra quan ha d'interpolat conjunts de dades per a pendents superiors a 1:12. Per aquest motiu, es procedeix a crear un nou model (model 2B) que sigui capaç de realitzar aquesta tasca. Recordant que la causa més probable del problema es troba en el sobreentrenament de la xarxa, s'entrena un nou conjunt d'ANN (taules 3C.18-19) amb les mateixes característiques que el model 2, però aquest cop

amb un menor nombre de neurones per capa oculta, i es força així la xarxa a augmentar la capacitat de generalització, encara que això suposi una disminució en la precisió d'estimació.

Arquitectura	5-20-22-1
Entrades	x, y, z, α, p
Sortida	\bar{C}_p
Funcions de transferència	Tangent sigmoïdal per a les capes ocultes Lineal per a la capa de sortida
Algoritme d'entrenament	Levenberg-Marquardt
<i>Epochs</i>	190
Eficiència de la xarxa (R)	0,9860

Taula 3C.18 Paràmetres de la xarxa Backpropagation destinada a la predicció de \bar{C}_p per al model 2B.

Arquitectura	5-19-20-1
Entrades	x, y, z, α, p
Sortida	\tilde{C}_p
Funcions de transferència	Tangent sigmoïdal per a la primera capa oculta Logarítmica sigmoïdal per a la segona capa oculta Lineal per a la capa de sortida
Algoritme d'entrenament	Levenberg-Marquardt
<i>Epochs</i>	250
Eficiència de la xarxa (R)	0,9882

Taula 3C.19. Paràmetres de la xarxa Backpropagation destinada a la predicció de \tilde{C}_p per al model 2B.

Abans d'examinar la capacitat del model 2B per interpol·lar nous pendents de teulada, es comprova si continua estimant, de forma correcta, els coeficients de pressió dels conjunts de dades reservats per a aquest propòsit. Així doncs, igual que per al model 2, es presenten els errors d'estimació de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada, l'RMSE dels 120 sensors de la *corner bay* i l'error de predicció de la força de sustentació que sofreix.

Model Teulada	H (m)	α	\bar{C}_p				\tilde{C}_p			
			Sensor cantonada			RMSE	Sensor cantonada			RMSE
			Experim.	ANN	Error (%)	(%)	Experim.	ANN	Error (%)	(%)
A	7,32	280°	-0,721	-0,719	-0,3	2,3	0,289	0,300	3,9	0,8
		300°	-0,681	-0,846	24,3	3,9	0,319	0,354	11,1	1,2
		320°	-0,551	-0,557	0,9	3,8	0,208	0,211	1,5	1,3
		340°	-0,773	-0,868	12,3	3,9	0,332	0,328	-1,2	1,1
	12,19	280°	-0,803	-0,806	0,3	4,0	0,334	0,353	5,6	1,4
		300°	-1,037	-1,182	14,1	5,5	0,420	0,397	-5,6	1,3
		320°	-0,814	-0,804	-1,1	5,4	0,267	0,291	8,8	1,7
		340°	-1,032	-1,120	8,5	5,2	0,410	0,391	-4,5	1,7

E	7,32	280°	-0,767	-0,702	-8,5	2,3	0,294	0,264	-10,3	0,7
		300°	-0,749	-0,700	-6,6	3,2	0,309	0,322	4,3	1,2
		320°	-0,539	-0,506	-6,2	3,3	0,213	0,204	-4,1	1,1
		340°	-0,758	-0,822	8,6	4,1	0,301	0,351	16,4	1,5
	12,19	280°	-0,937	-0,852	-9,1	3,2	0,369	0,355	-3,8	1,2
		300°	-1,061	-1,074	1,2	4,5	0,412	0,391	-5,3	1,2
		320°	-0,823	-0,744	-9,6	5,8	0,293	0,287	-1,9	1,9
		340°	-1,023	-1,075	5,1	5,3	0,387	0,422	9,2	1,9

F	7,32	280°	-0,435	-0,381	-12,3	2,2	0,176	0,179	1,4	0,8
		300°	-0,360	-0,248	-31,0	3,0	0,210	0,228	8,6	1,1
		320°	-0,381	-0,352	-7,7	3,3	0,288	0,228	-20,9	1,7
		340°	-0,780	-0,696	-10,8	3,9	0,322	0,358	11,1	1,4
	12,19	280°	-0,661	-0,669	1,2	3,1	0,251	0,259	2,9	0,8
		300°	-0,536	-0,542	1,2	3,6	0,265	0,315	18,8	1,3
		320°	-0,596	-0,529	-11,3	4,6	0,369	0,329	-10,7	1,7
		340°	-0,987	-0,936	-5,2	4,6	0,391	0,439	12,3	2,1

Error mitjà			8,2	3,9		7,7	1,3
-------------	--	--	-----	-----	--	-----	-----

Taula 3C.20 Error de predicció de \bar{C}_p i \tilde{C}_p per al sensor de la cantonada i RMSE de la predicció de \bar{C}_p i \tilde{C}_p per als 120 sensors de la *corner bay*.

Model Teulada	H (m)	α	\overline{F}_s <i>corner bay</i>		
			Experim.	ANN	Error (%)
A	7,32	280°	-0,238	-0,241	1,3
		300°	-0,229	-0,232	1,4
		320°	-0,267	-0,269	0,9
		340°	-0,299	-0,309	3,2
	12,19	280°	-0,346	-0,337	-2,4
		300°	-0,331	-0,330	-0,4
		320°	-0,375	-0,383	2,3
		340°	-0,436	-0,436	0,0

E	7,32	280°	-0,238	-0,232	-2,5
		300°	-0,223	-0,221	-1,2
		320°	-0,260	-0,263	1,3
		340°	-0,311	-0,308	-1,2
	12,19	280°	-0,334	-0,343	2,8
		300°	-0,335	-0,327	-2,4
		320°	-0,382	-0,374	-2,2
		340°	-0,421	-0,429	1,9

F	7,32	280°	-0,144	-0,147	2,3
		300°	-0,154	-0,158	2,6
		320°	-0,199	-0,193	-2,9
		340°	-0,270	-0,273	1,0
	12,19	280°	-0,247	-0,249	0,9
		300°	-0,242	-0,247	1,9
		320°	-0,291	-0,289	-0,6
		340°	-0,393	-0,378	-3,7

Error mitjà					1,8
-------------	--	--	--	--	-----

Taula 3C.21. Error en la predicció de la força de sustentació \overline{F}_s sobre la superfície de la *corner bay* per a cadascun dels 24 conjunts de dades no emprats en l'entrenament de l'ANN.

Si hom compara els resultats per al model 2B (taules 3C.20-21) amb els del model 2 (taules 3C.15-16), veurà que els errors han augmentat, especialment en l'estimació del sensor de la cantonada; però, de forma global, els resultats continuen sent bons. Aquest fet era d'esperar, ja que perquè les ANN del model 2B puguin generalitzar millor que les del model 2, cal que siguin més flexibles, i sacrificuin part de la precisió en l'estimació del valor d'un sensor en concret. A continuació es passa a mostrar com

aquest sacrifici permet a les ANN interpolat els conjunts de dades, dels nous pendents de teulada, de forma correcta. En primer lloc, es representa la força de sustentació (figura 3C.36) per a cada direcció de vent i una alçada de base de teulada de 7,32 m, dels tres nous pendents de teulada (línia discontinúta) i dels tres pendents de teulada dels quals es tenen dades experimentals (línia contínua). Com es pot observar, les línies discontinútes segueixen el comportament de les contínues i la seva posició s'adequa a la que hom pot esperar si es té en compte la relació de pendents que existeix entre ells.




Fig. 3C.36. Força de sustentació a la *corner bay*, calculada amb les dades experimentals dels models de teulada A, E i F i les dades generades per les ANN per als models J, K i L per a tots els angles d'incidència del vent i una alçada de la base de la teulada de 7,32 m.

En segon lloc, es mostra una selecció de les distribucions de \bar{C}_p (estimades pel model 2B) per al model a escala J (pendent 2:12), comparades amb les distribucions de les dades experimentals dels models a escala A i F (pendents 1:12 i 3:12, respectivament). S'escull l'estimació del pendent 2:12, ja que es troba a mig camí entre els pendents dels quals es disposa de dades experimentals (1:12 i 3:12).




Fig. 3C.37.1. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 285° , alçada de la base de la teulada de 7,32 m i un pendent de a) 1:12 (dades experimentals), b) 2:12 (dades estimades) i c) 3:12 (dades experimentals).




Fig. 3C.37.2. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 300° , alçada de la base de la teulada de 12,19 m i un pendent de a) 1:12 (dades experimentals), b) 2:12 (dades estimades) i c) 3:12 (dades experimentals).




Fig. 3C.37.3. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 315° , alçada de la base de la teulada de 7,32 m i un pendent de a) 1:12 (dades experimentals), b) 2:12 (dades estimades) i c) 3:12 (dades experimentals).




Fig. 3C.37.4. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 330° , alçada de la base de la teulada de 12,19 m i un pendent de a) 1:12 (dades experimentals), b) 2:12 (dades estimades) i c) 3:12 (dades experimentals).




Fig. 3C.37.5. Distribució de \bar{C}_p sobre una teulada amb angle d'incidència del vent de 330° , alçada de la base de la teulada de 7,32 m i un pendent de a) 1:12 (dades experimentals), b) 2:12 (dades estimades) i c) 3:12 (dades experimentals).

Observant les figures 3C.37.1-5, es pot veure com les distribucions de \bar{C}_p del pendent estimat (2:12) segueixen el comportament de les distribucions de les dades experimentals (pendents 1:12 i 3:12). Concretament, hom ho pot notar de forma clara en les dues zones on més influència exerceix el pendent de la teulada:

- La cantonada encarada a la direcció del vent ($x = 0$ i $y = 0$). A mesura que augmenta el pendent de la teulada, els valors de \bar{C}_p augmenten. Aquest comportament es pot veure al llarg del lateral de la teulada ($x = 0$).
- A sotavent de la carena de la teulada (zona central de la teulada i, per tant, el punt més alt, $x = 12,1$). A mesura que augmenta el pendent de la teulada, els valors de \bar{C}_p disminueixen a sotavent de la carena i de forma més pronunciada a l'extrem encarat a la direcció del vent ($y = 0$).

L'explicació física d'aquest comportament és que per a pendents molt suaus (teulades gairebé planes), el vent es desplaça de forma gairebé paral·lela a la superfície de la teulada, i es forma una capa límit sobre el lateral encarat al vent ($x = 0$) on disminueix la pressió, mentre que per a pendents més pronunciats, el vent ja no es mou de forma paral·lela a la teulada, sinó que part de la seva força impacta sobre la teulada (com més pendent, més força d'impacte), i fa que la pressió augmenti (comparada amb pendents més suaus). En canvi, a la carena hi passa l'efecte contrari; amb pendents suaus, la teulada és pràcticament plana i, per tant, la carena gairebé no sobresurt del pla de la teulada, sense interferir amb el flux de vent. Amb pendents més pronunciats, la zona situada a sotavent i adjacent a la carena pateix una força de succió a causa del flux de vent que sobrepassa la carena, provinent de sobrevent.




Fig. 3C.38.1. Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 280° , alçada de la base de la teulada de 12,19 m i un pendent de *a*) 1:12 (dades experimentals), *b*) 2:12 (dades estimades) i *c*) 3:12 (dades experimentals).




Fig. 3C.38.2. Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 305° , alçada de la base de la teulada de 7,32 m i un pendent de *a*) 1:12 (dades experimentals), *b*) 2:12 (dades estimades) i *c*) 3:12 (dades experimentals).




Fig. 3C.38.3. Distribució de \tilde{C}_p sobre una teulada amb angle d'incidència del vent de 345° , alçada de la base de la teulada de 12,19 m i un pendent de a) 1:12 (dades experimentals), b) 2:12 (dades estimades) i c) 3:12 (dades experimentals).

El mateix comportament es pot observar en les distribucions de \tilde{C}_p . Per a pendents suaus, els valors més alts de l'RMS es troben a la cantonada encarada al vent, mentre que a mesura que augmenta el pendent de la teulada, el valor d'RMS disminueix en aquesta zona i augmenta a sotavent de la carena. Observant les figures 3C.38.1-3, es pot veure com aquesta tendència és capturada i generada pel model 2B.

Un cop mostrats els resultats del primer sistema d'avaluació de l'eficàcia de les ANN, es presenten els resultats del segon sistema, que corresponen a la reconstrucció de les sèries temporals dels coeficients de pressió a partir dels valors interpolats de \bar{C}_p i \tilde{C}_p . Emprant l'equació 3C.9, s'han reconstruït les sèries temporals dels coeficients de pressió per a tots els sensors de cadascun dels vint-i-quatre conjunts de dades, i amb elles s'ha calculat la força de sustentació instantània (equació 3C.10) sobre la superfície de la teulada, de cada conjunt. Un cop obtinguda la sèrie temporal de la força de sustentació (F_s) de cada conjunt de dades, se'n calculen els quatre moments estadístics (mitjana, desviació estàndard, *skewness* i curtosi) i es comparen amb els corresponents valors de la sèrie temporal calculada a partir de les dades experimentals.

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,195	0,047	-0,377	3,104
		Estimat	-0,190	0,043	-0,396	3,192
		Error (%)	2,7	8,4	-4,9	-2,8
	300	Experimental	-0,183	0,041	-0,597	3,716
		Estimat	-0,184	0,043	-0,365	2,943
		Error (%)	-0,6	-5,0	38,9	20,8
	320	Experimental	-0,160	0,041	-0,541	3,268
		Estimat	-0,160	0,042	-0,520	3,172
		Error (%)	-0,1	-1,5	4,0	3,0
	340	Experimental	-0,129	0,037	-0,468	3,530
		Estimat	-0,127	0,035	-0,317	3,101
		Error (%)	1,5	4,3	32,2	12,2

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,251	0,062	-0,580	3,220
		Estimat	-0,257	0,061	-0,452	3,197
		Error (%)	-2,7	2,2	22,0	0,7
	300	Experimental	-0,256	0,058	-0,513	2,963
		Estimat	-0,255	0,056	-0,401	3,093
		Error (%)	0,5	2,1	21,9	-4,4
	320	Experimental	-0,229	0,051	-0,449	3,253
		Estimat	-0,226	0,051	-0,324	2,984
		Error (%)	1,0	-1,2	28,0	8,3
	340	Experimental	-0,178	0,045	-0,644	3,442
		Estimat	-0,182	0,044	-0,501	3,295
		Error (%)	-2,6	1,9	22,1	4,2

Error mitjà (%)		1,5	3,3	21,8	7,0
-----------------	--	-----	-----	------	-----

Taula 3C.22.1. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala A (pendent 1:12).

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,174	0,049	-0,525	3,402
		Estimat	-0,177	0,046	-0,462	3,105
		Error (%)	-1,6	5,6	12,1	8,7
	300	Experimental	-0,167	0,046	-0,505	3,236
		Estimat	-0,171	0,047	-0,372	2,984
		Error (%)	-2,3	-1,5	26,4	7,8
	320	Experimental	-0,146	0,041	-0,538	3,683
		Estimat	-0,147	0,042	-0,477	3,584
		Error (%)	-0,7	-2,0	11,2	2,7
	340	Experimental	-0,112	0,035	-0,404	3,057
		Estimat	-0,115	0,034	-0,365	3,188
		Error (%)	-2,2	2,8	9,6	-4,3

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,240	0,062	-0,541	3,233
		Estimat	-0,238	0,057	-0,410	3,187
		Error (%)	0,5	7,9	24,1	1,4
	300	Experimental	-0,229	0,053	-0,366	3,007
		Estimat	-0,230	0,054	-0,557	3,781
		Error (%)	-0,6	-2,0	-52,3	-25,7
	320	Experimental	-0,196	0,048	-0,441	3,382
		Estimat	-0,200	0,049	-0,519	3,467
		Error (%)	-2,2	-2,4	-17,9	-2,5
	340	Experimental	-0,163	0,044	-0,565	3,415
		Estimat	-0,165	0,045	-0,479	3,689
		Error (%)	-0,9	-1,0	15,3	-8,0

Error mitjà (%)			1,4	3,1	21,1	7,6
-----------------	--	--	-----	-----	------	-----

Taula 3C.22.2. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala E (pendent 1/4:12).

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
7,32	280	Experimental	-0,163	0,045	-0,516	3,301
		Estimat	-0,166	0,046	-0,610	3,421
		Error (%)	-1,7	-1,7	-18,2	-3,6
	300	Experimental	-0,182	0,053	-0,577	3,493
		Estimat	-0,180	0,049	-0,448	3,259
		Error (%)	1,1	7,7	22,3	6,7
	320	Experimental	-0,193	0,054	-0,500	3,240
		Estimat	-0,195	0,054	-0,486	3,264
		Error (%)	-0,9	1,4	2,8	-0,8
	340	Experimental	-0,205	0,061	-0,632	4,089
		Estimat	-0,202	0,062	-0,627	3,422
		Error (%)	1,7	-2,3	0,8	16,3

H (m)	α		Mitjana	Desv. est.	Skewness	Curtosi
12,19	280	Experimental	-0,259	0,068	-0,410	3,037
		Estimat	-0,261	0,066	-0,571	3,269
		Error (%)	-0,9	2,6	-39,2	-7,6
	300	Experimental	-0,265	0,065	-0,578	3,620
		Estimat	-0,262	0,067	-0,437	2,966
		Error (%)	1,3	-3,1	24,5	18,1
	320	Experimental	-0,276	0,067	-0,304	3,268
		Estimat	-0,270	0,069	-0,498	3,538
		Error (%)	2,1	-3,3	-63,9	-8,3
	340	Experimental	-0,299	0,081	-0,554	3,511
		Estimat	-0,287	0,084	-0,620	3,579
		Error (%)	3,8	-4,2	-12,0	-1,9

Error mitjà (%)		1,7	3,3	22,9	7,9
-----------------	--	-----	-----	------	-----

Taula 3C.22.3. Error en els quatre moments estadístics de l'estimació de la sèrie temporal de la força de sustentació sobre la teulada del model a escala F (pendent 3:12).

S'obté un error mitjà per als vint-i-quatre conjunts de dades de tan sols l'1,5% per a la mitjana i del 3,2% per a la desviació estàndard, amb un valor màxim del 3,8% i del 8,4%, respectivament. Pel que fa als errors en l'*skewness* i la curtosi, igual que per al model 1, són força més alts, sobretot en el primer. Com ja s'ha comentat, això es deu al fet que cap dels dos moments estadístics no s'ha tingut en compte en la reconstrucció de les sèries temporals dels coeficients de pressió (equació 3C.9). Els valors mitjans dels errors per a l'*skewness* i la curtosi són del 21,9 % per al primer i del 7,5 % per al segon, amb valors màxims del 63,9% i del 25,7%, respectivament.

Els conjunts de dades de referència que s'han escollit per a les reconstruccions corresponen, en cada cas, a un conjunt de dades amb les mateixes dimensions de teulada, pendent de teulada i alçada de la base de teulada, amb l'única diferència de l'angle d'incidència del vent, que s'ha buscat que fos tan similar com sigui possible al del conjunt de dades per reconstruir. És a dir, seguint la mateixa metodologia descrita i justificada per al model 1.

Per acabar, es mostren figures amb l'autoespectre de la sèrie temporal de la força de sustentació (F_s) estimada comparat amb el de la sèrie temporal experimental, per a quatre dels conjunts de dades estimats.




Fig. 3C.39.1. Autoespectre de la força de sustentació sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 280° i pendent de teulada $1/4:12$.




Fig. 3C.39.2. Autoespectre de la força de sustentació sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$, angle d'incidència del vent de 300° i pendent de teulada 1:12.

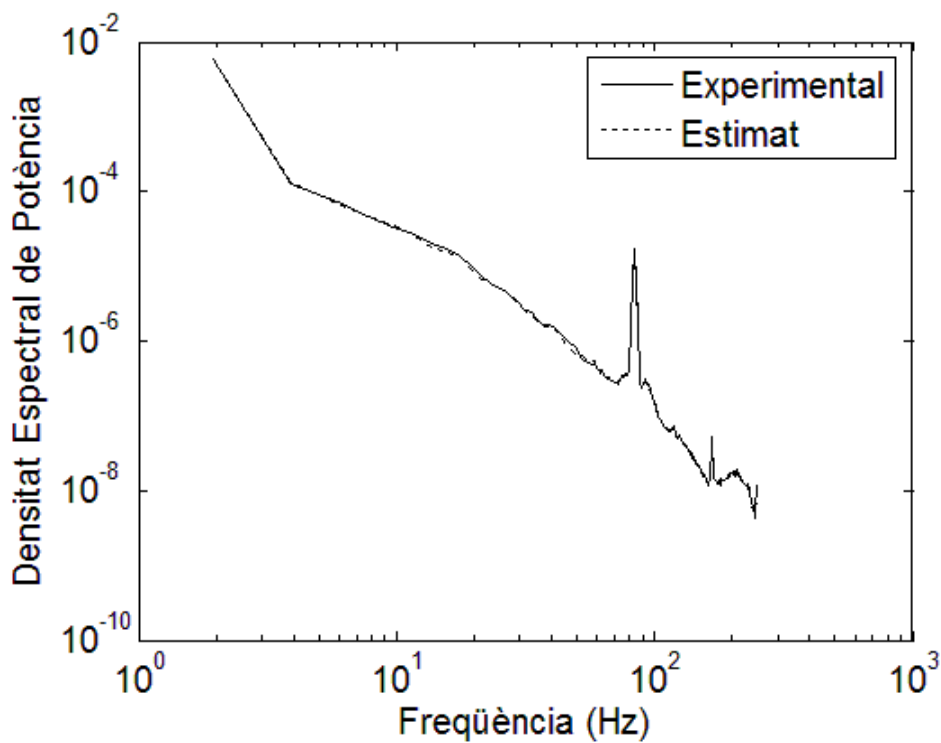


Fig. 3C.39.3. Autoespectre de la força de sustentació sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $7,32 \text{ m}$, angle d'incidència del vent de 320° i pendent de teulada 3:12.




Fig. 3C.39.4. Autoespectre de la força de sustentació sobre una teulada de dimensions $38,1 \text{ m} \times 24,4 \text{ m}$, alçada de la base de la teulada de $12,19 \text{ m}$, angle d'incidència del vent de 340° i pendent de teulada 3:12.

Es pot observar com, en els quatre casos (figures 3C.39.1-4), els autoespectres de les sèries temporals estimades són gairebé calcats als de les experimentals, la qual cosa demostra que la desviació estàndard de la força de sustentació és estimada correctament i que el comportament del vent sobre el model de referència és prou similar a l'estimat per compartir autoespectre. Per a la resta de conjunts de dades, s'han obtingut resultats similars.

3C.4 Conclusions

S'ha demostrat que les xarxes neuronals artificials (ANN) són capaces d'interpol·lar moments estadístics (mitjana i desviació estàndard) de dades de pressió sobre teulades de cases prefabricades de baixa alçada. Les ANN han estat capaces d'interpol·lar dades entre models a escala de diferents dimensions de teulada, angle d'incidència del vent, pendent de teulada i alçada de la base de la teulada, i han mostrat una gran capacitat de generalització.

La selecció i mètode de normalització de les dades d'entrada a les xarxes que s'ha desenvolupat ha permès que les prediccions dels moments estadístics fossin acurades en tota la superfície de les teulades, fins i tot en les zones més conflictives com són la

corner bay i el sotavent de la carena, zona on els treballs anteriors de Chen et al. (2003b) no van obtenir bons resultats.

L'eficiència dels dos models d'ANN ha permès un càlcul precís de la força mitjana de sustentació a què es veuen sotmeses les teulades dels conjunts de dades estimats, i ha demostrat que l'aplicació del model d'interpolació desenvolupat permet realitzar càlculs de càrregues aerodinàmiques amb una exactitud similar a la que s'obté amb les simulacions en túnels de vent, de manera que es redueix clarament el cost de dur a terme aquests estudis.

Finalment, s'ha mostrat que és possible reconstruir les sèries temporals de pressions, a partir dels dos moments estadístics interpolats per les ANN, i obtenir de nou bons resultats en l'aplicació en el càlcul de càrregues aerodinàmiques, que tanta importància tenen en el disseny de les teulades de les cases prefabricades.

Per tant, es pot afirmar que la metodologia descrita en aquest treball permet el seu ús en la interpolació i ampliació corresponent de les bases de dades de coeficients de pressió sobre teulades de baixa alçada.

3.1 Referències

ASCE (2002). *ASCE 7-02. Minimum design loads for buildings and other structures. Revision of ANSI/ASCE 7-98*. Reston.

BASU, R. I. (1982). *Across-wind response of slender structures of circular cross-section to atmospheric turbulence*, vol. 1 i 2. Ph-D. Thesis. Universitat de Western Ontario, Canadà.

BELTZER, A. I.; T. SATO (2003). „Neural classification of finite elements”, *Computers and Structures* 81, 2331-2335.

CHEN, Y.; G. A. KOPP; D. SURRY (2003a). “Interpolation of pressure time series in an aerodynamic database for low buildings”, *J. Wind. Eng. Ind. Aerodyn.* 91, 737-765.

— (2003b). “Prediction of pressure coefficients on roofs of low buildings using artificial neural networks”, *J. Wind. Eng. Ind. Aerodyn.* 91, 423-441.

ENGINEERING SCIENCE DATA UNIT (ESDU) (1974). “Characteristics of atmospheric turbulence near the ground”, *Data Item* 74031.

— (1982). “Strong winds in the atmosphere boundary layer. Part 1: Mean-hourly wind speeds”, *Data Item* 82026.

— (1983). “Strong winds in the atmosphere boundary layer. Part 2: Discrete gust speeds”, *Data Item* 83045.

GALSWORTHY, J. (2000). *Aspects of across-wind loads and effects on large reinforced*

concrete chimneys. Ph-D Thesis. Universitat de Western Ontario, Canadà.

GIOFFRÈ, M.; V. GUSELLA; M. GRIGORIU (2000). "Simulation of non-Gaussian field applied to wind pressure fluctuations", *Probab. Eng. Mech.* 15, 339-345.

— (2001). "Non-Gaussian wind pressure on prismatic buildings. II. numerical simulation", *J. Struct. Eng.* 127 (9), 990-995.

GIRALT, F.; A. ARENAS; J. FERRÉ-GINÉ; R. RALLO; G. A. KOPP (2000). "The simulation and interpretation of turbulence with a cognitive neural system", *Phys Fluids* 12, 1826.

GURLEY, K.; M. A. TOGNARELLI; A. KAREEM (1997). "Analysis and simulation tools for wind engineering", *Probab. Eng. Mech.* 12 (1), 9-31.

HAYKIN, S. (1994). *Neural Networks: a comprehensive foundation*. Nova York: Macmillan Publishing.

HUSH, D. R.; B. G. HORNE (1993). "Progress in supervised neural networks: what is new since lippmann?", *IEEE Signal Process. Mag.* 10, 8-39.

KOPP, G. A.; Y. CHEN (2006). "Database-Assisted Design of Low-Rise Buildings: Aerodynamic Considerations for a Practical Interpolation Scheme", *J. Struct. Eng.* 132(6), 909-917.

LIN, J. X.; D. SURRY, D.; H. W. TIELEMAN (1995). "The distribution of pressure near roof corners of flat roof low buildings", *J. Wind. Eng. Ind. Aerodyn.* 56, 235-265.

LIN, J. X.; D. SURRY (1998). "The variation of peak loads with tributary area near corners on flat low building roofs", *J. Wind. Eng. Ind. Aerodyn.* 77-78, 185-196.

POPESCU, R.; G. DEODATIS; J. H. PREVOST (1998). "Simulation of homogeneous non-Gaussian stochastic vector fields", *Probab. Eng. Mech.* 13, 1-13.

ZDRAVKOVICH, M. M. (1997). *Flow around circular cylinders. Volume 1: Fundamentals*. Oxford University Press.

Capítol 4. Conclusions

Al llarg del capítol 3, s'ha demostrat que els models basats en xarxes neuronals artificials (ANN) són capaços de predir coeficients de pressió, complint amb l'objectiu d'aquest treball, tal com indica el títol de la tesi. Per ser més precisos, es pot afirmar que els models de predicció/interpolació basats en ANN són capaços de capturar la dinàmica de fluxos altament turbulents.

El treball amb el sistema dinàmic del cilindre, immers en condicions altament turbulentes, ha permès demostrar que:

1. Les ANN són capaces de capturar la dinàmica de la turbulència a partir, únicament, de dades experimentals de pressions.
2. És possible classificar zones amb comportaments similars de la turbulència emprant, únicament, valors estadístics de sèries temporals de pressions.
3. Es poden reconstruir sèries temporals de pressions a partir de la seva mitjana i desviació estàndard i una sèrie temporal de referència amb la qual comparteixi similituds.

Aquestes conclusions han permès desenvolupar l'aplicació pràctica d'aquest treball, que consta de la realització d'un model d'interpolació de la base de dades del United States National Institute of Standards and Technology (NIST). El model desenvolupat és capaç, a partir de les dades temporals de pressions existents, de predir de forma precisa la mitjana i la desviació estàndard de sèries temporals de pressions sobre una teulada amb les següents característiques fixades per l'usuari del model (dins el rang vàlid d'interpolació):

- Amplada i llargada de la teulada.
- Pendent de la teulada.
- Alçada de la base de la teulada.
- Angle d'incidència del vent.

Amb aquestes dades, i seguint la metodologia validada amb el sistema dinàmic del cilindre, s'ha demostrat que és possible reconstruir les sèries temporals de les pressions i calcular, de forma acurada, les càrregues aerodinàmiques a les quals es veurà sotmesa la teulada de les característiques fixades per l'usuari del model.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Capítol 5. Treball futur i recomanacions

Com a continuació del treball presentat en aquesta tesi, es plantegen dues línies de treball per seguir:

- Crear un model global d'interpolació de la base de dades del NIST en lloc dels dos models per separat que s'han desenvolupat en aquest treball. Per dur-ho a terme, caldria disposar de més dades experimentals (conjunts de dades de diferents pendents de teulada per a totes les dimensions de teulada estudiades), o, en cas que no fos possible disposar de més dades experimentals, crear un sistema de normalització, de les dades d'entrada al model, comú per als dos models i intentar entrenar una sola xarxa amb tots els conjunts de dades disponibles a la base de dades del NIST.
- Desenvolupar un programari que incorpori el model d'interpolació junt amb el càlcul de càrregues estructurals, de forma que l'usuari final, introduint únicament les característiques d'una teulada, obtingui la informació sobre les càrregues estructurals màximes a les quals es veurà sotmesa.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Annex

A continuació, s'adjunten els tres articles científics que s'han escrit a partir de la recerca duta a terme durant la realització d'aquesta tesi. El primer ja ha estat publicat, el segon és un esborrany pendent d'enviar i el tercer ja ha estat enviat i està pendent que s'accepti.

Annex A. Simulating pressure coefficients on a circular cylinder at $Re = 10^6$ by cognitive classifiers.

Annex B. Classification and generation of pressure coefficients on a circular cylinder at $Re = 10^6$ using artificial neural networks.

Annex C. Interpolation of pressure coefficients for low-rise building of different plan dimensions and roof slopes using artificial neural networks.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Annex A

Simulating pressure coefficients on a circular cylinder at
 $Re = 10^6$ by cognitive classifiers.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010



Contents lists available at ScienceDirect

Computers and Structures

journal homepage: www.elsevier.com/locate/compstruc



Simulating pressure coefficients on a circular cylinder at $Re = 10^6$ by cognitive classifiers

X. Gavalda^a, J. Ferrer-Gener^b, Gregory A. Kopp^c, Francesc Giralt^{a,*}, J. Galsworthy^c

^a *Departament d'Enginyeria Química, Universitat Rovira i Virgili, 43007 Tarragona, Catalunya, Spain*

^b *Departament d'Enginyeria, Informàtica i Matemàtiques, Universitat Rovira i Virgili, 43007 Tarragona, Catalunya, Spain*

^c *Boundary Layer Wind Tunnel Laboratory, Faculty of Engineering, University of Western Ontario, London, ON, Canada N6A 5B9*

ARTICLE INFO

Article history:

Received 6 April 2008

Accepted 30 March 2009

Available online 25 April 2009

Keywords:

Circular cylinder

Wind loads

Forecasting time-series

Fuzzy ARTMAP

ABSTRACT

A system formed by multiple fuzzy ARTMAP neural algorithms, operating in parallel, was applied to capture the dynamics of surface pressures from a circular cylinder in cross flow and to forecast the time histories. Pressure data measured at all locations around the section at earlier instants of time were needed to yield accurate temporal predictions of the lower order statistics of pressure, lift and drag. However, using data from only a few adjacent pressure taps at earlier times was not sufficient since pressure in incompressible turbulent flows depends on velocity fluctuations over the entire flow domain.

© 2009 Elsevier Ltd. All rights reserved.

1. Introduction

The determination or calculation of spatial and temporal variations of physical variables in transient processes is important in many engineering applications. Examples include the active control of various processes, prediction of system behavior for the design of a process or product, and forecasting future behavior based on the current or previous state of a system or process. Often, this is done by solving the equations representing the physical laws that govern the process or system. Alternatively, when first principle models cannot be solved accurately, approximate engineering equations or empirical models have to be used.

For practical problems related to fluid flow, the governing equations are difficult to solve directly in situations where the Reynolds number is high and turbulence occurs. In these situations, approximate forms of the governing equations are often used with empirically based, or calibrated, turbulence models. Numerical solutions often work reasonably well for engineering design purposes, and can be used with confidence since available experimental data are used to confirm results or at least to calibrate and validate the turbulence models. The above limitations are aggravated in the case of the wind acting on buildings and other structures located in complex terrain (e.g., hills, adjacent buildings, etc.) because Reynolds numbers are high, the geometries are complex, and large computational domains have to be covered by the models. Although significant progress has been made recently in CFD

applications to wind-driven phenomena on both low-rise and high-rise buildings [1,2], current models have not made significant inroads into the design process for this particular class of problems. Rather, designers rely either on wind tunnel test results, databases from experiments, or the provisions in building codes.

Given that experiments are often difficult and costly, it is, thus, reasonable to consider alternative approaches which can make a greater use of the data available. This may lead to a loss of generality, but it brings the benefit of increased simplicity or speed. For example, the ASCE 7-05 Minimum Design Loads for Buildings and Other Structures [3] currently allows the use of databases, rather than relying only on the simplified design charts contained within the standard. Databases of this sort are never 'complete' in the sense that (i) the range of variation in shape of buildings will always be larger than the range of experimental data available, and (ii) only a subset of the relevant physical data is contained in the database. Regarding the latter point, and for the particular case considered here, surface pressure data are available, but flow (i.e., velocity) field variables which cause the surface pressure field are not. These issues have been discussed in greater detail in Kopp and Chen [4], as related to interpolation of pressures pertaining to the NIST aerodynamic database [5,6] for wind loads on low buildings.

One of the significant challenges that must be faced in the process of designing a computational framework capable of generating new (interpolated) data from the information contained in existing databases is to determine whether or not the pressure field over building surfaces contains, in itself, all of the information necessary to predict the (surface) pressure fluctuations at all locations and times. The explicit relationship of pressure to velocity is

* Corresponding author. Tel.: +34 977 559 638; fax: +34 977 559 621.
E-mail address: fgiralt@urv.cat (F. Giralt).

obtained by taking the divergence of the Navier–Stokes equations [7,8], such that

$$\frac{\partial^2 P}{\partial x_i^2} = -\rho_o \frac{\partial^2 V_i V_j}{\partial x_i \partial x_j}, \quad (1)$$

where P is the pressure, ρ_o is the fluid density and V_i is the velocity. Considering a statistically stationary process, Corcos [7] shows that the pressure fluctuations, p , are a function of the velocity fluctuations such that

$$\frac{\partial^2 p}{\partial x_i^2} = -2\rho_o \frac{\partial \bar{V}_i \partial v_j}{\partial x_j \partial x_i} - \rho_o \frac{\partial^2 [v_i v_j - \bar{v}_i \bar{v}_j]}{\partial x_i \partial x_j}, \quad (2)$$

where the overbar indicates the time mean and the lower case letters are for fluctuations. To obtain the pressure fluctuations at a surface, Eq. (2) has to be integrated over the flow domain [7]. Thus, the surface pressure fluctuations at any instant depend on spatial gradients of the mean and fluctuating velocity vectors over the flow domain at that same instant. Given the nature of the turbulent velocity field, there are some features of the velocity that selectively affect pressure fluctuations at particular locations to greater or lesser extents than fluctuations at other locations (e.g., blocking of free stream turbulent fluctuations at particular scales near the surface). In particular, the pressure field has less fine scale structure than the velocity field [7].

From a statistical point of view, surface pressure fluctuations in a turbulent stream are highly non-Gaussian such that the extreme values (which are critical for design) can have peak factors which are significantly greater than the expected value of ~ 4 for a Gaussian process [9]. As well, the spatial and temporal characteristics of correlations depend on a wide range of parameters and vary significantly over building surfaces. The nonlinear interactions of the turbulence upstream of the structure with turbulence generated by the structure [10] plays an important role. These characteristics undoubtedly affect simulation performance, no matter which method is chosen.

Several methodologies have been applied to model this class of problems [11–16]. Most of the work has focused on statistically-based stochastic simulation methods [11–14], although neural networks are beginning to be used. For example, Fu et al. [15] predicted wind-induced pressures on a large gymnasium roof with backpropagation and fuzzy neural networks. Beltzer and Sato [16], dealing with the classification of finite elements using Self-Organizing Maps (SOM), categorized a large amount of pressure information from a single building into a smaller number of class proxies.

The aim of the current study is to develop a computational system utilizing several fuzzy ARTMAP neural algorithms operating in parallel to capture the spatial and temporal wind-induced pressures for a particular structure. The fuzzy ARTMAP algorithm was considered the best candidate for predicting instantaneous surface pressures since it was successfully applied by Giralt et al. [17] to forecast the instantaneous turbulent velocity field at multiple locations simultaneously in a fully developed wake. The flow around a circular cylinder in cross flow at high Reynolds number ($Re = 10^6$), while simple in geometry involves complex flow phenomena such as free stream turbulence, turbulent flow separations and vortex shedding. In [17], a relatively simple architecture with multiple fuzzy ARTMAP networks operating in parallel led to an efficient time series prediction scheme since the individual networks were able to effectively capture the patterns of the velocity fluctuations in a turbulent cylinder wake. In fact, the neural algorithm became an analogue for the Navier–Stokes equations and was able to capture both the spatial and temporal flow dynamics. The current analysis considers a data set which has significantly more complex spatial characteristics. The degree of complexity of the fuzzy ART-

MAP architecture and the configuration of the input data needed to capture the most relevant dynamic events of the pressure field over the cylinder surface are both examined. The degree of accuracy of the predicted pressure signals should provide an indication about the general feasibility of data-driven models to generate wind-induced pressures at high Reynolds numbers on structures (such as buildings) from pressure information only. In addition, since there is no explicit equation for the time evolution of the pressure field, which depends implicitly on the evolution of the velocity field as indicated by Eq. (1), while spatial gradients are defined explicitly by the Navier–Stokes equations, part of the current effort is also aimed at determining the most appropriate arrangement for the temporal input information that may (or may not) be required to develop data-driven models for wind-induced pressures on buildings.

2. Experimental data

While the focus of this work is not the cylinder data discussed below, it is important to understand them before evaluating the performance of the neural network simulations presented later in the paper. Fig. 1 shows a definition sketch of the experimental set-up. A rigid circular cylinder with a diameter $D = 50$ cm was placed in a uniform flow with a free stream speed, $U = 30.0$ m/s, so that the Reynolds number based on the diameter was $Re = 1.0 \times 10^6$. The free stream was turbulent with an intensity of about 5% and an integral scale of $L_{ii} \sim 14$ cm ($L_{ii}/D = 0.28$). Thirty-two equally spaced pressure taps were placed around the circumference of the cylinder. Each pressure transducer was sampled at 200 samples/s over 60 s. The pressure tubing system response was flat to 40 Hz. Further details pertaining to the experiments can be found in Galsworthy [18].

Fig. 2a depicts the standard deviation of the experimental pressure coefficients, $C_{p\sigma}$. Fig. 2b shows short intervals of the time histories of the lift coefficient and of pressure coefficients at few selected taps. Several observations can be made from Fig. 2. First, data are asymmetric due to an asymmetry in the experimental set-up which consisted of an open jet wind tunnel [18]. While from a fluid mechanics perspective such an asymmetry should be avoided, it does provide an additional challenge for the simulation technique. While the physical behavior of the flow on the two sides of the cylinder is only slightly altered, the asymmetry significantly alters the symmetry of the higher order statistics of the pressure field. Second, the spatial variations of the fluctuations are significant with elevated levels near the separation points between roughly $90\text{--}120^\circ$ and $240\text{--}270^\circ$. Third, the frequency of fluctuations changes significantly with location, as can be inferred from the time series segments in Fig. 2b. This is due to the relatively different scales of the free stream turbulence and of the vortex shedding process. The magnitude of $C_{p\sigma}$ in the region close the stagnation point is governed by free stream turbulence and can be predicted with quasi-steady theory [19,20]. This theory also indicates that $C_{p\sigma}$ should increase prior to flow separation, as is observed in Fig. 2.




Fig. 1. Definition sketch of the experimental set-up for flow around a cylinder of diameter, $D = 0.5$ m and free stream velocity, $U = 30$ m/s.

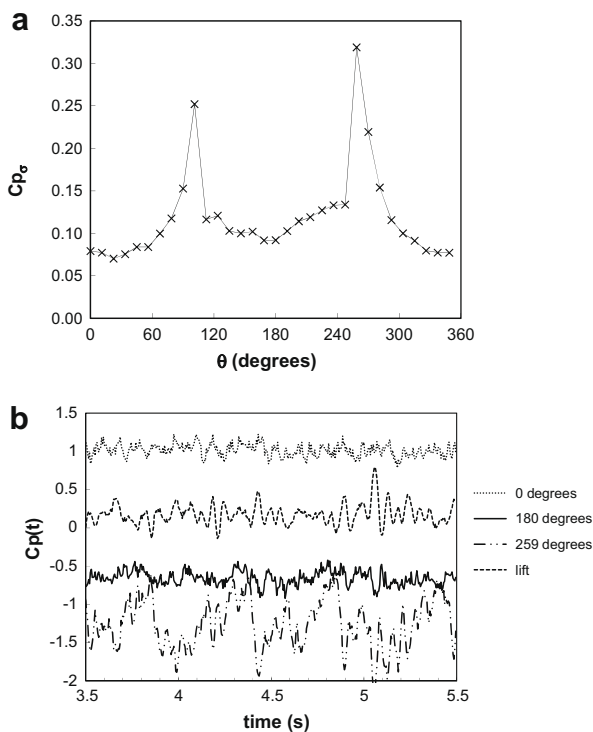


Fig. 2. Experimental values of the (a) standard deviation of the pressure coefficients, and (b) a segment of time series of the pressure coefficients (mean values included) at select locations.

Vortex shedding from circular cylinders has been the subject of numerous studies, although there has been relatively limited work at the high Reynolds numbers examined here. Zdravkovich [21] provides a comprehensive review. The Strouhal number for the current experiments was 0.27, as obtained from the power spectrum of the lift fluctuations calculated by integrating the pressure time histories. Examination of the pressure time series in Fig. 2b indicates that instants of coherent shedding (e.g., around $t = 5.0$ – 5.3 s) alternate with others of more erratic pressure patterns (e.g., around $t = 4.6$ – 4.8 s). Pressure fluctuations induced by shedding are less pronounced than those observed in the lift, except close to the separation points (θ between 90 – 120° and 240 – 270°) where Cp_σ is higher.

Fig. 3 shows the spatial correlations at zero time-lag, $\varphi = \overline{Cp_i Cp_j} / \overline{Cp_{\sigma i} Cp_{\sigma j}}$, for several reference locations around the cylinder, where Cp_i is the fluctuating pressure coefficient at tap i , with corresponding $Cp_{\sigma i}$, while the subscript j refers to tap j . The spatial correlations near the stagnation point exhibit an integral scale of similar order of magnitude as the upstream turbulence. In contrast, the correlations relative to the base region are observed to be significantly and positively correlated between $\sim 60^\circ < \theta < \sim 300^\circ$. The correlation between the taps at $\theta = 101^\circ$ and 259° (i.e., between the points of maximum Cp_σ , near the mean locations of the separation) is positive and small ($\varphi \sim 0.07$). The fact that this correlation is not significantly negative indicates that the effects of the free stream and/or boundary layer turbulence, compared to the vortex shedding, are significant. However, on either the upper or lower sides of the cylinder, the spatial correlation on the same side relative to the separation is positive and is of significant magnitude. This indicates that the contribution from vortex shedding is reasonably strong.

The correlations between pressure fluctuations at the separation point and on the other side of the cylinder are close to zero, as can be seen in Fig. 3. This could be because of the counteracting




Fig. 3. Spatial correlations for zero time lag, φ , with reference pressure taps at various locations around the cylinder.

effects of free stream turbulence and vortex shedding. On the one hand, considering the small integral scale of free stream turbulence, both the velocity and induced pressure fluctuations should be uncorrelated around the cylinder. Note that large scale velocity fluctuations, with a scale $L \gg D$, would lead to a positive pressure correlation around the cylinder, while small-scale fluctuations, $L \ll D$, would be uncorrelated around the cylinder. On the other hand, the flapping of the separated shear layers from the two sides (because of vortex shedding) is known to lead to pressure fluctuations which are out of phase on the two sides, causing a negative correlation at zero time lag. Clearly, there could also be nonlinear interactions between the free stream turbulence and the vortex shedding. Evidently, the disordering effects of the free stream turbulence govern the resulting correlations to some extent.

In summary, the turbulent flow data should provide a significant challenge for a simulation technique. The relatively simple geometry and small number of taps required to capture the phenomena provide a good test case for a data-driven simulation tool such as fuzzy ARTMAP neural networks.

3. Fuzzy ARTMAP algorithm

3.1. Background

Artificial neural networks (ANN) are computational algorithms that process input–output information. They consist of two types of components; neurons and synaptic connections. The neurons are the information processing elements, which contain linear or nonlinear transfer functions or rules. The synaptic connections transfer information between the neurons and define the intensity and the destination of the signals from the neurons or from the input. Because of this structure, neural networks are often used to solve multivariate and nonlinear problems. However, there is no theoretical basis for determining the optimal network type and configuration for any given problem; rather, this is determined in an ad hoc manner. There are a wide variety of neural network models [22–24], which differ in terms of structure and mode of operation. These include multilayer networks, single layer perceptrons, Carpenter networks, Hamming networks, Hopfield networks, and Radial Basis Function networks, to name but a few. Many utilize Euclidean metrics to classify information, like the SOM [25,26], while others apply fuzzy logic, such as the Fuzzy ARTMAP neural network [27–30]. The fuzzy ARTMAP algorithm, described in greater detail below, is used to determine the amount and type of infor-

mation needed to generate statistically accurate pressures time-series for the current problem, as well as to evaluate the extent to which these time-series can be forecast from pressure information only.

In Giralt et al. [17], the input data configuration that was adopted to forecast instantaneous velocities in a turbulent wake included (simulated) velocities from adjacent sensors with high correlations at one previous time, and of the same sensor at a number of earlier moments in time determined by the fractal dimension of the signals. The relationships between pressures and velocities in a turbulent incompressible flow, given by Eqs. (1) and (2), require that both temporal and spatial information be considered for the sensor examined as well as for the adjacent locations. Thus, the current input data arrangement takes the form,

$$p_i(t+1) = f[p_i(t), p_i(t-1), \dots, p_i(t-n), \dots, p_{i+m}(t), p_{i+m}(t-1), \dots, p_{i+m}(t-n)], \quad (3)$$

where $p_i(t+1)$, is the forecasted pressure for sensor i at time $(t+1)$ from previous information at times $(t+n)$, $n \approx 11$ (i.e., of the order of the temporal integral time scale of pressure) and adjacent sensors $(1+m)$, $m \leq 31$. With stochastic simulation methods, f is determined by probability density functions, autospectra and correlation matrices which are obtained from the available data. In the current neural network approach, f is determined by the clusters of pressure patterns, defined by the specific space-time input information, which are obtained from the implementation of fuzzy ARTMAP, as described below. Thus, predictions with statistical and neural network approaches are constrained by data.

4. Definitions

The characteristic function of a set A , which in turn is a subset of the reference set E depicted in Fig. 4 ($A \subset E$), can be defined as,

$$\phi_A : A \rightarrow \{0, 1\}, \\ x \in A \rightarrow 1, \\ x \notin A \rightarrow 0. \quad (4)$$

The similarity between two fuzzy sets A and B can be established by means of subsethood measures, i.e., measures of set inclusion, $A \subset B$. Thus, the measure of fuzzy subsethood requires the definition of a membership function.

Zadeh [31] introduced the idea of fuzzy sets to deal efficiently with uncertainty. A fuzzy set A on a Boolean set E is defined as follows:

$$A = \{x, \mu_A(x) | x \in E\}, \quad (5)$$

where the membership function

$$\mu_A : E \rightarrow [0, 1], \\ x \rightarrow \mu_A(x) \quad (6)$$

quantifies the grade of membership of each element of the reference set E to the subset A . A grade equal to zero indicates that the affected element is not included in the given set A , while a grade of one corresponds to fully included members. Grade values between 0 and 1 characterize fuzzy members. Thus, a fuzzy set can be expressed as a vector with components $[0, 1]$ when the reference set is established.

If $A = (a_1, a_2, \dots, a_k)$, $B = (b_1, b_2, \dots, b_k)$ are two fuzzy sets, denoted as vectors with elements equal to the membership function, the degree to which A is a fuzzy subset of B is given by

$$\text{degree (A fuzzy subset of B)} = \frac{|A \wedge B|}{|A|}, \quad (7)$$

where the fuzzy **and** operator, \wedge , is defined by $(A \wedge B)_i = \min(a_i, b_i)$, the norm is defined by $|A| = \sum_{i=1}^k a_i$, and k is the cardinal of the reference set. Thus, two sets can be compared with an infinite gradation of memberships in the interval $[0, 1]$ with the application of fuzzy theory. This is particularly relevant in the current study since the equality between sets of experimental data, which are noisy, is difficult to establish.

5. The fuzzy ARTMAP algorithm

The fuzzy ARTMAP neural system [27–30] is a classifier that links input patterns with the sought classification output or supervisor. The dynamics of fuzzy ARTMAP are essentially the same as that of two separate Fuzzy ART networks, each one working with one part of the input training vectors, with an associative memory recording the link between the classes corresponding to the input pattern and the desired classification. Fig. 5 depicts a schematic representation of the fuzzy ARTMAP neural system. A detailed description of the network architecture applied to the classification of vortices can be found in Ferre-Gine et al. [32,33].

In the current problem, fuzzy ARTMAP models were developed to forecast the pressure at each tap at a future time (fuzzy set B) from pressures at other taps for some previous instants of time (fuzzy set A). Several input configurations to ART_A were considered to assess the temporal and spatial information needed to enable pressure forecasting capabilities in the ART_B module. The two fuzzy ART modules (ART_A and ART_B) apply fuzzy set theory to perform the classification tasks. The presentation of the 1st vector, which is formed by the related first elements of fuzzy sets A and B , to ART_A and ART_B creates the 1st categories in both modules. Each category is represented by a centroid which initially is the first committing vector. The subsethood degree of the 2nd vector to the existing 1st

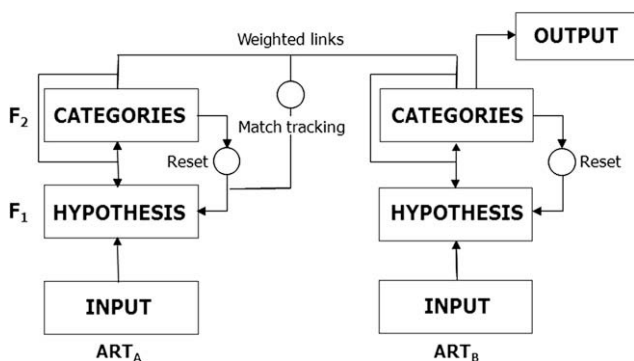


Fig. 4. Fuzzy ARTMAP architecture for each simulated pressure tap.

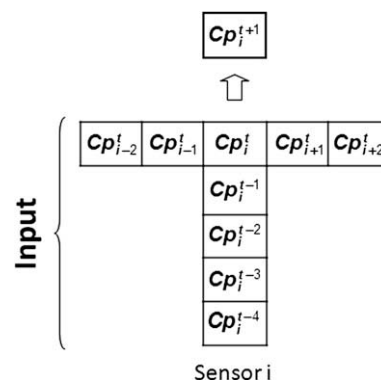


Fig. 5. Typical input/output arrangement for the simulation of sensor i in the configuration FAM₅₋₁₋₅.

categories (Eqs. (5)–(7)) determines whether this 2nd vector is also assigned/classified to the 1st categories or whether a new category is needed; the threshold is set by a vigilance parameter. This process continues until all input vectors have been classified according to a membership criterion. This process is always convergent [30]. Thus, each fuzzy ART module classifies inputs in an unsupervised manner and only takes the subethood relationship into consideration. A map, relating the two modules, fixes the links between the categories formed, while an internal controller, called match tracking, performs resets over the input whenever the map shows any classification contradiction. Thus, the system avoids any one (ART_A) to many (ART_B) relationships between inputs (A, B). Mechanisms to speed up the process and to conduct a proper classification can be found in Carpenter et al. [29].

Modifications in the configuration depicted in Fig. 5 were made by Giralt et al. [17] to allow the forecasting of the velocity field in a turbulent wake. In the present work, one fuzzy ARTMAP network was assigned to each sensor and trained by using the same basic network architecture as in the earlier study, although the input vectors were altered, as discussed below. The individual networks associated with each of the pressure taps were first trained with pressure data and the output in Fig. 5 disconnected. Training vectors for the ART_A module included different combinations of pressure data. Sequential time-information from the given sensor and from adjacent sensors were considered. The subsequent pressure data points in the time sequence of each tap signal (i.e., vectors with single elements), which are the targets of any of the current forecasting models, were used to train the ART_B module in parallel. Thus, space–time pressure information over the cylinder was provided simultaneously to the neural system formed by several fuzzy ARTMAP networks, one network for each pressure tap, with past and present information provided to each ART_A module and the corresponding future information to each ART_B module. There was no other association between individual networks. The generation of simulated pressure signals at all taps was accomplished by running all the individual fuzzy ARTMAP models developed for each pressure tap simultaneously and in parallel. This enabled predicted pressures at any location at the cylinder surface to be used as input in the next time-steps within the forecasting sequence.

6. Results and discussion

6.1. Pressure patterns

To illustrate both the unsupervised classification capabilities of a fuzzy ART module and the complexity of the multiple scales of pressure fluctuations at the cylinder due to local and global flow phenomena, pressure patterns were classified and analyzed. Most of pressure events (89% of the total pressure signals measured by the 32 sensors) were assigned to ART classes, each containing at least 40 patterns. The remaining 11% of the data were identified as single class events where pressure fluctuations in one or more pressure taps exceeded the rms pressure value by at least a factor of 3.

Fig. 6 depicts plots of two representative patterns of the pressure fluctuations that correspond to the set of classified patterns. The left plots (Fig. 6a and c) show the patterns as pressure coefficient values, while the two right ones (Fig. 6b and d) are normalized with respect by the corresponding rms. values at each tap. For these normalized patterns, the relative, local fluctuations are weighted equally. Note that in the current experiments at $Re = 10^6$ the separation points are approximately located close to sensors 10 (101.25°) and 24 (258.75°). The two patterns in Fig. 6 were selected because the former represents events with a strong downwards lift fluctuation (Fig. 6a), with a small suction at the for-

ward stagnation point (0°) caused by a small negative free stream velocity fluctuation, while the second pattern represents the opposite (i.e., an upward lift fluctuation in Fig. 6c with a slightly higher pressure at 0°). In both cases they show large pressure fluctuations in their primitive values near the two separation points (i.e. at 101.25° and 258.75°) in a clear indication of the occurrence of vortex shedding phenomena.

While the patterns in Fig. 6 share similarities when compared symmetrically with respect to the horizontal mid-plane they also show differences that become more evident when pressure fluctuations at each tap are normalized by their corresponding rms. value. Fig. 6a, and to a greater extent Fig. 6b, show that downstream of the separation points, the pressure patterns are more complex, with alternating negative and positive fluctuations, than those found in the base region of a cylinder in uniform, smooth flow at lower Re , even when it oscillates [34]. These spatial pressure changes are consistent with the correlation relative to the tap at 101° , shown in Fig. 3. In addition, it also explains the differences in the correlations relative to the tap at 180° due to the positive and negative pressure fluctuations on either side. The large positive fluctuation at around 230° , visible in Fig. 6b, is likely due to a boundary layer event and/or to free stream turbulence. Velocity field information is needed to ascertain its genesis. The pressure distribution in Fig. 6b becomes a star-like pattern in Fig. 6d due to the high activity with negative and positive pressure fluctuations at 101° and 258° , respectively, caused by vortex shedding. The tap at approximately 340° is particularly active, relative its rms. value, in this pattern. The relatively small spatial coherence of the pattern compared to normal vortex shedding (for a recent example see the pressure patterns reported by Zasso et al. [34] for high amplitude vortex-induced oscillation of a circular cylinder) suggests that the large fluctuation at 340° was caused by a small-scale fluctuation in the free stream. As discussed in the Section 2, it is clear that free stream turbulence is causing a significant disruption of the shedding process and that the high Re turbulent boundary layer also contributes to the de-correlation of the flow around the cylinder, and this has significant influence on the clusters of patterns in the data. Fig. 6b and d shows that even downstream of the separation points significant fluctuations occur instead of the quasi-uniform pressures that are normally observed in the base region of a cylinder in crossflow.

The above results indicate that a large set of pressure information would be needed to capture all of the possible patterns that exist and contribute to the measured spatial and temporal fluctuations, as illustrated by the two patterns depicted in Fig. 6. An analysis of the characteristics of all the classes of pressure patterns identified by fuzzy ART indicates that despite many broad similarities in many types of patterns there are differences that have to be accounted for in detail to capture the multiple scales present in the flow system and which make the time series prediction a challenging problem. Thus, high-dimensional input information, both in space and time, are required in the fuzzy ARTMAP-based pressure models to deal with all of the smaller scale and free stream turbulence-based events.

6.2. Models

Table 1 lists six particular input/output configurations tested to forecast the instantaneous pressure time histories at each location by applying Eq. (3). This process has to be synchronous and simultaneous because the input to any one of the 32 ART_A modules of the fuzzy ARTMAP (FAM) architecture (depicted in Fig. 4) includes pressure information from neighbouring sensors at previous instants of time, each of which also has to be predicted. The nomenclature used in Table 1 to identify the different input configurations is $FAM_{a,b,c}$, where a indicates the number of taps in-

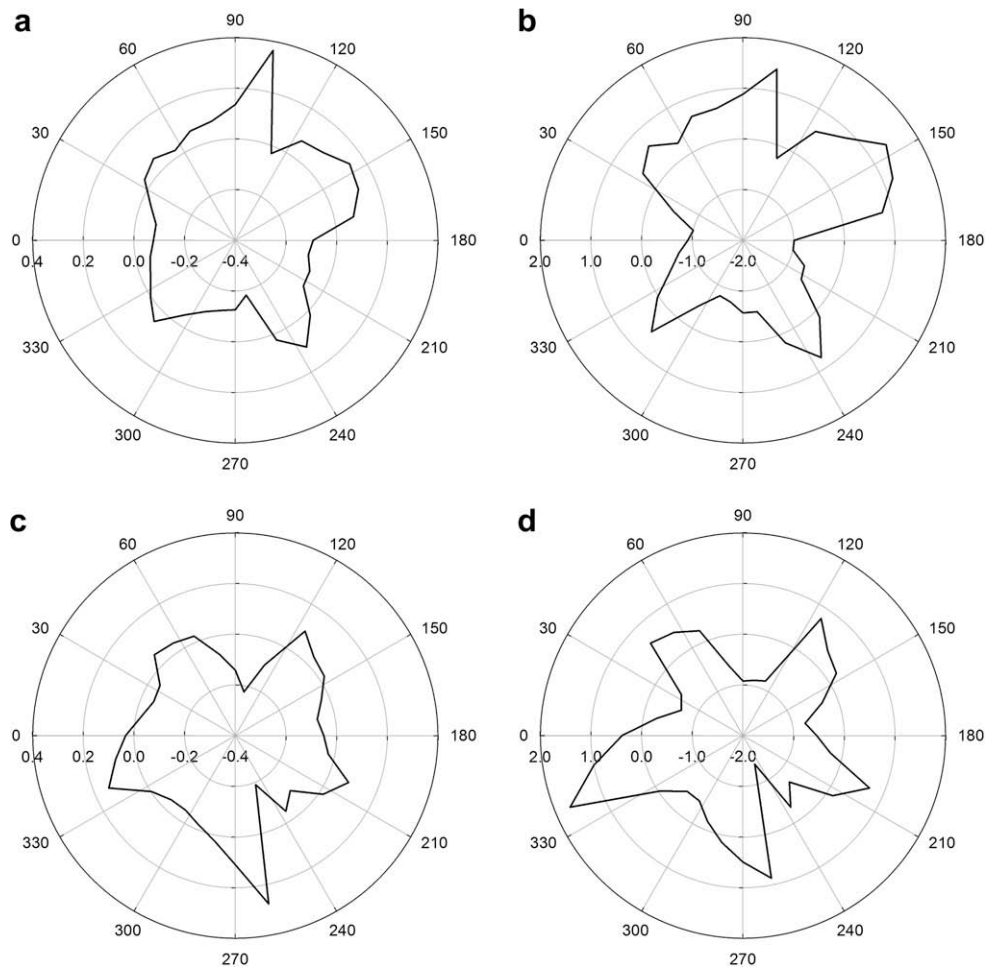


Fig. 6. Two examples of representative pressure fluctuations patterns expressed in terms of primitive pressures (a, c) and values normalized with respect to the rms of fluctuations measured at each tap (b, d).

Table 1
Summary of the input data configurations in the fuzzy ARTMAP network.

Input data configuration	No. input taps, a	No. time instants, b/c	Total no. of elements in input vector
FAM _{5,1,5}	5	1/5	9
FAM _{5,4,12}	5	4/12	28
FAM _{8,1,1}	8	1/1	8
FAM _{32,1,1}	32	1/1	32
FAM _{32,4,4}	32	4/4	128
FAM _{32,11,11}	32	11/11	352

involved, b is the number of previous time instants considered for neighbouring taps, and c is the number of previous time instants considered for the tap whose pressure is being forecasted. For example, Fig. 5 depicts the input structure for the FAM_{5,1,5} configuration reported in Table 1. (This particular input configuration is similar to the one we used in [17].) Pressure Cp_i^{t+1} from sensor i at time $(t + 1)$ is predicted at the ART_B module (in Fig. 5) when the input pressure information (depicted in Fig. 5) is fed to module ART_A of each network involved. These input pressures are those predicted in the previous time-step, t , for the five sensors considered, plus four additional data points for sensor i up to previous times $(t - 4)$. Except for the initial experimental data that are used to initiate the forecasting process (which were unseen to the networks previously), input patterns are formed from pressures predicted by the preceding time-steps. The computations for all six

Table 2
Summary of errors for the standard deviations of the predicted lift, drag and pressure coefficient fluctuations.

Architecture	ε_L (%)	ε_D (%)	ε_P (%)
FAM _{5,1,5}	-37	-1.1	15
FAM _{5,4,12}	-49	-33	29
FAM _{8,1,1}	-28	-12	6.6
FAM _{32,1,1}	-8.9	-1.5	4.4
FAM _{32,4,4}	+2.1	-1.4	1.8
FAM _{32,11,11}	-3.2	-7.5	0.2

input arrangements (and many others not reported here) were made on SHARCNET at the University of Western Ontario [35].

Table 2 summarizes the performance of the networks in terms of the average error on Cp_σ , where

$$\varepsilon_p = \sum_{i=1}^{32} \left| \frac{(\sigma_{p,sim,i} - \sigma_{p,exp,i})}{\sigma_{p,exp,i}} \right| \cdot 100\% \quad (8)$$

and the subscript 'sim' refers to the simulated data and 'exp' to the experimental data. The errors in the fluctuating lift (ε_L) and drag (ε_D), obtained via pressure integration, are also given, while the values of Cp_σ obtained via the simulation can be found in Fig. 7. One would expect that the accuracy of integral parameters, such as the lift and drag, to depend on the accurate estimation of point values. This is generally observed to be the case and is consistent with the fact that the errors in the lift fluctuations exceed the errors in




Fig. 7. Experimental and simulated values of the standard deviation of the pressure coefficient fluctuations, $C_{p\sigma}$, versus tap location.

the point pressure fluctuations (although this is not always the case with the drag). The most accurate predictions are clearly related to the most accurate spatial information so that the FAM₃₂ networks are the most accurate, particularly in the vicinity of the separated shear layers.

The FAM₅ and FAM₈ structures, which have input information from only the four and seven immediately adjacent taps, respectively, are able to capture the fluctuations in the vicinity of the stagnation point reasonably well. However, the magnitude of the fluctuations downstream of the separation point is significantly underestimated. Thus, the effects of the free stream turbulence at the leading edge are mostly captured while vortex shedding is not with these input configurations. The large errors observed between $\theta \sim 60^\circ$ and 300° in Fig. 7 also suggest that the nature of the velocity field in the vicinity, and downstream, of the separation points is only properly accounted for when information of all pressure taps are considered in the model. Perhaps this is the reason for the reasonable to excellent accuracy with which the fluctuations are captured with the FAM₃₂ networks. However, in order to establish this point, and also to determine why important aspects like the lift and drag fluctuations are accurately predicted, correlations, spectra, and higher order moments need be examined. This is done further below.

Fig. 8 shows the zero time lag, spatial correlations, ϕ , from the experimental and simulated data relative to the taps at $\theta = 0^\circ$ and 101° , while Fig. 9 shows the autocorrelations for these same locations. All three FAM₃₂ networks accurately capture the experimental correlations, although the FAM_{32,1,1} and FAM_{32,4,4} are superior to the FAM_{32,11,11}. In contrast, the FAM_{5,1,5}, and FAM_{5,4,12} and FAM_{8,1,1} networks drop off far too fast at the neighboring taps, indicating why the lift and drag fluctuations are not well simulated with these two networks. This is somewhat surprising since adjacent taps are part of the input configuration for both networks. From a statistical point of view, the input information spans a large portion of the integral scale with the adjacent four and seven taps, even in the region near the separated flow, so one would expect that sufficient information should be contained in the input patterns to capture the fluctuations. This was certainly the case in our earlier work on the simulation of turbulent velocity fields [17], but is not the case here. Clearly, the input patterns do not contain sufficient information to capture what is happening at adjacent taps unless the pressures around the entire section are included. This result seems justified when considering that the surface pressure fluctuations depend on the entire turbulent velocity field through the integration of Eq. (2) over the flow domain. This fact seems to have a profound effect on the simulation of the surface pressure field since the pressure patterns around the entire cylinder are required to capture the full fluctuation energy at any





Fig. 8. Experimental and simulated correlations, ϕ , relative to a pressure tap at (a) $\theta = 0^\circ$ and (b) $\theta = 101^\circ$.

given point. Thus, one can conclude that the proxy information to Eq. (2) is the surface pressure data around the entire body, and this is sufficient to capture pressure fluctuations at any given point on the body.

One of the interesting aspects of the results in Figs. 7 and 8 is that the FAM_{32,11,11} network is less accurate than the FAM_{32,4,4} even though it contains more temporal information in the input data. Given that the fuzzy ARTMAP is based, to some extent, on clustering and fuzzy sets, it appears that greater input information hinders pattern identification so that the input–output relationship is less reliable. This could be related to the stochastic nature of the pressure patterns and to an increasing effect of the 11% of rare pressure events (with fluctuations larger than three times the rms.) over time scales longer than the temporal integral scale of the pressures. This integral time-scale is less than 0.025 s at the stagnation point (and much longer at the separation points because of the mixed effects of vortex shedding and free stream turbulence at this point, as discussed in relation to Fig. 6), as can be inferred from Fig. 9. Given that the free stream turbulence is governing to a significant extent, as pointed out in Section 2 above, it appears that the optimum amount of temporal information is related to integral time scale of the pressure fluctuations around the stagnation point, and this is related directly to the free stream turbulence.

Fig. 9 shows some other interesting features in the simulated data. For example, the FAM_{5,4,12} network does not capture the temporal fluctuations at the stagnation point ($\theta = 0^\circ$) any better than FAM_{5,1,5} does. This indicates that Eq. (2), and the relationship of pressures to velocity fluctuations in the entire flow domain, is more important to the quality of the simulation than a “complete”

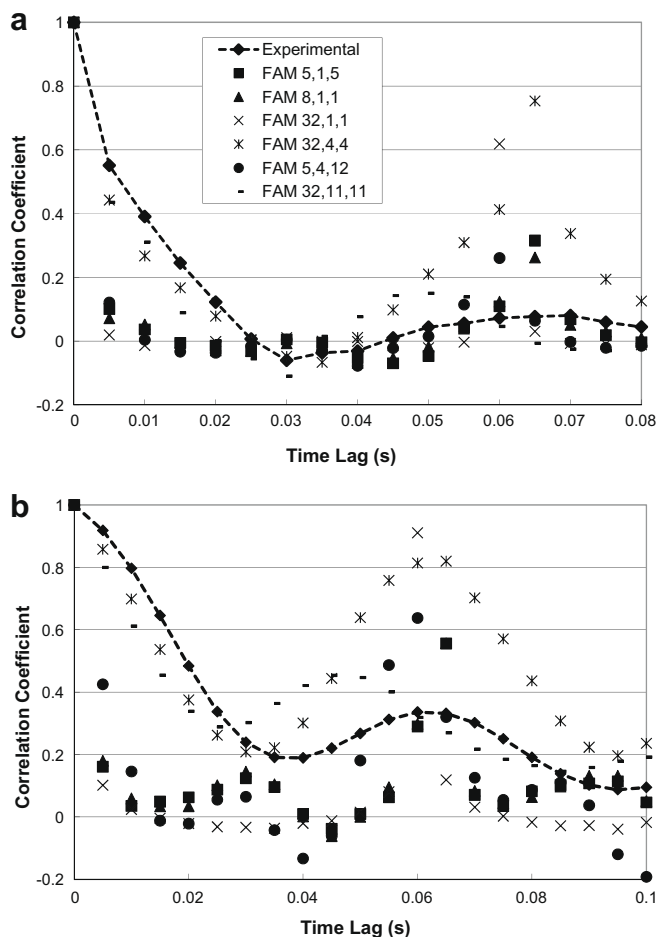


Fig. 9. Experimental and simulated autocorrelations for (a) $\theta = 0^\circ$ and (b) $\theta = 101^\circ$.

temporal description is. This is also the case for the FAM₃₂ networks, where the simulation considering 4 historical data points is superior to that with 11. While the FAM_{32,4,4} overestimates the effects of vortex shedding at the separation point ($\theta = 101^\circ$), the FAM_{32,11,11} actually gets the frequency of shedding wrong. Interestingly, all of the input arrangements (except FAM_{8,1,1}) overestimate the correlation with the time lag corresponding to one shedding cycle.

Fig. 10 depicts the distribution of skewness calculated from the simulated FAM_{32,4,4} data, as well as the experimentally measured values. The trends in the skewness are well captured, following the trends in the experimental data, as well as the magnitude at most locations. This indicates that the simulation is reasonably able to capture the peak pressures, an important point should such methods be ultimately used for interpolation of data for wind design of structures.

Spectra of the lift fluctuations are shown in Fig. 11 for both the experimental and simulated FAM_{32,4,4} data. The network captures the low frequency end of the spectrum quite well, as well as the energy content at the vortex shedding frequency and at higher frequencies. However, the spectrum of the simulated data falls off too rapidly between the low frequency end and the vortex shedding frequency. For the other networks (not shown here), the match at low frequencies is also poor, indicating why the standard deviations tend to be underestimated. This could be related to the number of temporal points included in the input vector since, of all the networks, the FAM_{32,11,11} has more accurate spectral content in this range, but at the cost of a significant mismatch of the shedding frequency. In any case, the overestimation of the autocorrelation at




Fig. 10. Comparison between the skewness distribution determined experimentally and calculated with the FAM_{32,4,4} model.




Fig. 11. Power spectral density (PSD) of lift fluctuations from the experimental and simulated FAM_{32,4,4} data.

vortex shedding frequencies is likely related to the low energy content at slower frequencies so that the simulated data appear to over-emphasize this feature of the data. In fact, the FAM_{32,4,4} does tend to over-predict the energy content of the shedding, as can be seen in Fig. 11, although only to a relatively small extent.

7. Conclusions

Several fuzzy ARTMAP neural networks were used to simulate surface pressure data around one section of a circular cylinder placed in a uniform free stream containing small scale turbulence at a Reynolds number of 10^6 . The following conclusions can be made. First, information from around the complete section is required to simulate the pressure distribution with sufficient accuracy so that the standard deviations and skewnesses of the pressures as well as the integrated lift fluctuations are accurately obtained. This information is sufficient to capture the flow physics, which dictate that the surface pressures depend on the turbulent velocity field in the entire flow domain. Temporal information is less important than spatial information for the fidelity of the simulations. However, the amount of temporal information in the input data is important for accurately simulating the spectral content of the data at the lower range of frequencies. Since the free stream turbulence was a governing feature of the data, integral scales directly associated with this yield the most accurate simulations. Using greater amounts of temporal information in the input

data leads to greater randomness in the input–output relationship in the network such that the simulation quality can degrade with too much temporal input data.

Thus, the results suggest that the pressure field over the cylinder surface at very high Reynolds numbers in a turbulent free stream does contain all of the requisite information that is needed to build a robust data-driven model which will capture the relevant fluid flow phenomena that affect the surface pressure fluctuations.

Acknowledgements

The current study was supported by the Grants FIS2005-07194 (MEC, Spain) and 2005SGR-00735 (DURSI, Generalitat de Catalunya). Francesc Giralte acknowledges the Distinguished Researcher Award, Generalitat de Catalunya. Gregory Kopp gratefully acknowledges the support of the Canada Research Chairs Program. This work was made possible by the facilities of the Shared Hierarchical Academic Research Computing Network (SHARCNET), as well as by the Senior Visiting Fellowship held by J. Ferrer-Gener during the portion of the work carried out in Canada.

References

- [1] Blocken B, Carmeliet J. Validation of CFD simulations of wind-driven rain on a low-rise building façade. *Build Environ* 2007;42:2530–48.
- [2] Huang S, Lib QS, Xu S. Numerical evaluation of wind effects on a tall steel building by CFD. *J Construct Steel Res* 2007;63:612–27.
- [3] ASCE 7-05. Minimum design loads for buildings and other structures. American Society of Civil Engineers 2006, Reston, VA, United States.
- [4] Kopp GA, Chen Y. Database-assisted design of low-rise buildings: aerodynamic considerations for a practical interpolation scheme. *ASCE J Struct Eng* 2006;132:909–17.
- [5] Ho TCE, Surry D, Morrish D, Kopp GA. The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 1. Archiving format and basic aerodynamic data. *J Wind Eng Ind Aerodyn* 2005;93:1–30.
- [6] St. Pierre LM, Kopp GA, Surry D, Ho TCE. The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 2. Comparison of data with wind load provisions. *J Wind Eng Ind Aerodyn* 2005;93:31–59.
- [7] Corcos GM. The structure of the turbulent pressure field in boundary layer flows. *J Fluid Mech* 1964;18:353–78.
- [8] Chevray R, Mathieu J. Topics in fluid mechanics. Cambridge University Press; 1993.
- [9] Kopp GA, Surry D, Mans C. Wind effects of parapets on low buildings: Part 4. Mitigation of corner loads with alternative geometries. *J Wind Eng Ind Aerodyn* 2005;93:873–88.
- [10] Saathoff PJ, Melbourne WH. Effects of free-stream turbulence on surface pressure fluctuations in a separation bubble. *J Fluid Mech* 1997;337:1–24.
- [11] Gurley K, Tognarelli MA, Kareem A. Analysis and simulation tools for wind engineering. *Prob Eng Mech* 1997;12:9–31.
- [12] Popescu R, Deodatis G, Prevost JH. Simulation of homogeneous nonGaussian stochastic vector fields. *Prob Eng Mech* 1998;13:1–13.
- [13] Gioffrè M, Gusella V, Grigoriu M. Simulation of non-Gaussian field applied to wind pressure fluctuations. *Prob Eng Mech* 2000;15:339–45.
- [14] Gioffrè M, Gusella V, Grigoriu M. Non-Gaussian wind pressure on prismatic buildings. II. numerical simulation. *ASCE J Struct Eng* 2001;127:990–5.
- [15] Fu JY, Liang SG, Li QS. Prediction of wind-induced pressures on a large gymnasium roof using artificial neural networks. *Comput Struct* 2007;85:179–92.
- [16] Beltzer AI, Sato T. Neural classification of finite elements. *Comput Struct* 2003;81:2331–5.
- [17] Giralte F, Arenas A, Ferre-Giné J, Rallo R, Kopp GA. The simulation and interpretation of turbulence with a cognitive neural system. *Phys Fluids* 2000;12:1826–35.
- [18] Galsworthy J. Aspects of across-wind loads and effects on large reinforced concrete chimneys. PhD thesis, University of Western Ontario; 2000.
- [19] Hunt JCR, Kawai H, Ramsey SR, Pedrizetti G, Perkins RJ. A review of velocity and pressure fluctuations in turbulent flows around bluff bodies. *J Wind Eng Ind Aerodyn* 1990;35:49–85.
- [20] Hölscher N, Niemann HJ. Turbulence and separation induced pressure fluctuations on a finite circular cylinder – application of a linear unsteady strip theory. *J Wind Eng Ind Aerodyn* 1996;65:335–46.
- [21] Zdravkovich MM. Flow around circular cylinders. Fundamentals, vol. 1. Oxford University Press; 1997.
- [22] Haykin S. Neural networks: a comprehensive foundation. Macmillan Publishing; 1994.
- [23] Flood I, Kartam N. Neural networks in civil engineering. I: principles and understanding. *J Comp Civ Eng* 1994;8:131–48.
- [24] Hush DR, Horne BG. Progress in supervised neural networks: what is new since Lippmann? *IEEE Signal Proc Mag* 1993;1:8–39.
- [25] Kohonen T. The self-organizing map. *Proc IEEE Conf* 1990;78:1464–80.
- [26] Kohonen T. Self-organizing maps: optimization approaches. In: Kohonen T, Mäkisara K, Simula O, Kangas J, editors. Artificial neural networks. Amsterdam: North-Holland; 1991. p. 981–90.
- [27] Carpenter GA, Grossberg S. A massively parallel architecture for a self-organizing pattern recognition machine. *Comp Vision Graphics Image Proc* 1987;37:54–115.
- [28] Carpenter GA, Reynolds Grossberg S. ARTMAP: supervised real-time learning and classification of non-stationary data by a self-organizing neural network. *Neural Net* 1991;4:565–88.
- [29] Carpenter GA, Grossberg S, Rosen D. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. *Neural Net* 1991;4:759–71.
- [30] Carpenter GA, Grossberg S, Marcuzon N, Reynolds JH, Rosen DB. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Trans Neural Net* 1992;3:698–713.
- [31] Zadeh L. Fuzzy sets. *Inform Control* 1965;8:338–53.
- [32] Ferre-Giné J, Rallo R, Arenas A, Giralte F. Identification of coherent structures in turbulent shear flows with a fuzzy ARTMAP neural network. *Int J Neural Sys* 1996;7:559–68.
- [33] Ferre-Giné J, Rallo R, Arenas A, Giralte F. Extraction of structures from turbulent signals. *Art Intel Eng* 1997;11:413–9.
- [34] Zasso A, Belloli M, Giappino S, Muggiasca S. Pressure field analysis on oscillating circular cylinder. *J Fluids Struct* 2008;24:628–50.
- [35] <<http://www.sharcnet.ca/my/about>> [accessed 30.03.08].

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Annex B

Classification and generation of pressure coefficients on a circular cylinder at $Re = 10^6$ using artificial neural networks.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Classification and generation of pressure coefficients on a circular cylinder at $Re = 10^6$ using artificial neural networks

X. Gavalda^{1a}, J. Ferrer-Gener^{1b}, G.A. Kopp², Francesc Giralt^{1a}

¹Grup de Fenòmens de Transport, ^aDept. Enginyeria Química, ^bDept. Enginyeria Informàtica i Matemàtiques, Universitat Rovira i Virgili, 43007 Tarragona, Catalunya, Spain

²Boundary Layer Wind Tunnel Laboratory, Faculty of Engineering, University of Western Ontario, London, ON, N6A 5B9, Canada

Abstract

In the current study, clustering and interpolation tools were assessed for surface pressure time series, measured at 32 locations over a circular cylinder in cross flow at $Re = 10^6$. A classification of the pressure sensors by means of Self-Organizing Maps (SOM) and k-means algorithm have been done and employed in obtaining pressure signal estimates within each class of surface sensors. Representative locations for each sensor class were identified and used as proxies to generate pressure signals for the remaining class members, yielding good approximations up to the 4th moment. Average and RMS of time-fluctuations of lift and drag coefficients were satisfactorily predicted, corroborating the well agreement between predicted and experimental pressure time series.

Keywords: circular cylinder, loads on buildings, time-series interpolation, neural classifier, self-organizing maps, high Reynolds number flow, clustering.

1. Introduction

The prediction of surface pressure time series in buildings is important to avoid structural failure under extreme wind conditions. Numerical calculations such as LES are not readily applicable to estimate loads on buildings at the high Reynolds numbers that occur under atmospheric conditions and the use of databank information is necessary. Because of the wide range of conditions in which buildings can be involved, as wind acting on adjacent buildings and other structures located in a complex terrain, databanks can not cover all the possibilities, since experiments are often difficult to carry out and are costly. Therefore, it would be worthy to increase the databanks

information by means of interpolation tools that use only experimental data contained by the databanks, avoiding the necessity of relying on new wind tunnel test results.

Experimental data usually only contains a subset of the relevant physical data as there is a finite space, where data can be stored, and there are too many experimental conditions to measure all the variables involved. For the case considered here, only surface pressure data is available, but not the flow (i.e., velocity) field variables which causes the pressure field. These issues have been discussed in greater details in Kopp and Chen (2006), as related to interpolation of pressure pertaining to the NIST aerodynamic database (Ho et al., 2005; St. Pierre et al., 2005) for wind loads on low buildings. For this reason, a secondary objective of the present work is to check if scalar pressure fields are enough to interpolate surface pressure fluctuations, verifying if these data contain, by themselves, some of the features of the turbulent three-dimensional velocity field that affect to pressure fluctuations, at particular locations, in an uncorrelated manner to patterns sensed at other locations. But the main challenge of this work is to assess the viability of classifying the pressure signals and coefficients, needed to calculate wind loads, for a given building into a few classes, so that class representatives could be used as proxies to generate data for the rest of class member locations. Neural classifiers are candidates to implement such an approach. The work of Beltzer and Sato (2003), dealing with the classification of finite elements with Self-Organizing Maps (SOM), suggests that, this neural algorithm, could be adequate to categorize the large amount of pressure information available on a single building into a smaller number of class proxies. Any reliable classification procedure would result in a reduction of the dimension of the problem, since locations with similar pressure patterns would form a class, that could be represented by the measurement point with pressure characteristics closest to the centroid of the class, i.e., by the proxy or prototype of that class.

Such methodology is better suited for databank interpolation and to real applications, since it reduces the dimension of the problem from many locations to lesser classes, where linear transformations, based on similar pressure data statistics, can be easily and consistently applied to all class member locations to forecast instantaneous pressure signals. Vectors formed by the second, third and fourth statistical moments, of instantaneous pressure signals, will be used to classify pressure patterns into consistent sensor classes, i.e., classes reflecting similar footprints left over the surface by free stream turbulence, shear layers and vortex shedding, by means of Self-Organizing Maps (SOM). Transformation-based methodologies, based on invariant properties of the statistical moments, will be applied to the resulting fewer classes, each characterized by a single prototype vector (proxy) and checked for membership consistency, to generate instantaneous pressure signals for any class-member data point.

The pressure data used in this work comes from a flow system consisting in a circular cylinder in cross flow under high turbulent conditions ($Re = 10^6$). This system has been selected because the geometry is simple and the complex fluid phenomena that occur at

these conditions, namely free stream turbulence, shear layers and vortex shedding, are also found in buildings. Section 2 gives a detailed account of the circular cylinder pressure experiments. The algorithms used are described in section 3 while results are presented and discussed in section 4. Finally, concluding remarks are given in section 5.

2. Experimental data

Fig. 1 shows a definition sketch of the experimental set-up. A rigid circular cylinder with a diameter $D = 50$ cm was placed in a uniform velocity $U = 30.0$ m/s cross stream, so that Reynolds number was $Re = 1.0 \times 10^6$. The free stream was turbulent with an intensity of about 5% and an integral scale of $L_u \sim 14$ cm ($L_u/D = 0.28$). Thirty two equally spaced pressure taps were placed around the circumference of the cylinder. Each channel sampled data at 200 samples/s over 60 s. The pressure tubing system response was flat to 40 Hz. Further details pertaining to the experiments can be found in Galsworthy (2000).

The first four statistical moments (mean, rms, skewness and kurtosis) are extracted from the 32 instantaneous pressure time-series. To magnify the importance of the second, third and fourth moments for further calculations, the mean of each time-series is subtracted, obtaining 32 instantaneous pressure fluctuation time-series with mean equal to 0 and keeping the other 3 moments from the pressure time-series.

3. Algorithms

3.1 Artificial neural networks

Artificial neural networks (ANN) are computational algorithms that process input – output information by means of processing elements (neurons), which are highly interconnected, with connections given by nonlinear transfer functions. Because of their structure, they are often used to solve multivariate and nonlinear problems. However, there is no theoretical basis for determining the optimum neural network type and configuration for a given problem. This often has to be determined on an ad-hoc basis. There are a variety of neural network models (Haykin, 1994; Flood and Kartam, 1994; Hush and Horne, 1993) which differ in terms of structure and mode of operation.

Self-Organizing Map. The self-organizing map (SOM) is an unsupervised neural network algorithm that projects (classifies) high dimensional data into a 2 or 3 dimensional grid of neurons (units), while preserving the original topology of the input space (Kohonen, 1997). This facilitates the visualization of hidden relationships that might be present in the data set. The neurons, or map units, are connected to each other by a neighborhood relationship that governs the structure of the map, as illustrated in Fig. 2. The algorithm is based on competitive learning (Kohonen, 1997; Kangas et al., 1990; Kaski and Lagus, 1996) where neurons gradually become sensitive to different

input categories present in a domain of the input space. Each neuron (unit or cluster) has a prototype vector $m_i = [m_{i1}, m_{i2}, \dots, m_{in}]$ (in the current work the second, third and fourth moments of the pressure time-series) that represents all data points (vectors) classified as pertaining to that unit i , where n is the dimension of the input space.

Training the SOM is sequential and begins with the random selection of one data point P of the input dataset, followed by the computation of distances between $\mathbf{P}=[P_1, \dots, P_n]$ and the prototype vector m_i of every node of the SOM. The elements m_{in} of the closest node to P (named the winner unit or Best Matching Unit, BMU) are updated, i.e., moved the most in the direction of the corresponding elements of \mathbf{P} , while adjacent nodes (neighbors) are changed depending on their distance from the winner unit in the initial geometry. The update rule for the prototype vector m_i of the winner unit i is given by:

$$m_i = m_i + \alpha(t)h_{ci}(t)(\mathbf{P}-m_i) \quad (1)$$

where $\alpha(t)$ is the learning rate, $h_{ci}(t)$ is the neighborhood function (generally a Gaussian function of distance), and \mathbf{P} the input sample vector. In the current study the elements of vectors \mathbf{P} are the second, third and fourth statistical moments of the pressure signals at each tap. The updating procedure of eq. (1) displaces the BMU and neighbors towards the vector \mathbf{P} presented to the map and classified in node m_i during training. The adjacent neurons or units of any neuron m_i define its neighborhood $N_i(t)$. Its value is generally defined as a decreasing function of the number of iterations or times (epochs) that the input data are presented to the map for training. The training process ends when all data points of the input dataset have been classified. Usually, the quality of a SOM is evaluated by the mapping precision, i.e., how accurately the neurons 'respond' to the given data set, and by the topology preservation, i.e., how well the SOM preserves the topology of the data set.

The optimal dimension of the map was determined by minimizing the topographic error proposed by Kiviluoto (1996) and the topological quantization error proposed by Kaski and Lagus (1996). The hexagonal neighborhood was complemented with a toroidal configuration of the map to eliminate border effects in the mapping process, i.e., all units in the map had six neighbors.

The SOM is a powerful classification tool that over the years has provided several good alternatives for visualization purposes. The unified distance matrix of distances between all nodes in the map, or U-matrix, is perhaps the most popular method to display SOMs. The component planes are also an additional analysis and visualization tool since they provide the distribution, over the map, of each element or variable of the input vectors P . Straightforward correlations and relationships in the input data can be found by comparing several component planes (C-planes) at the same time (Kaski, 1997; Laine, 2003).

3.2 Pressure data transformations

The application of SOM to classify vectors formed by the second, third and fourth statistical moments, of these pressures, signals should be sufficient to identify similar sensors and cluster the data into a smaller number of sensor classes. This classification will reduce the dimension of the problem by identifying the minimum number of representative pressure taps needed to capture the ‘footprints’ left on the scalar pressure field by the flow regimes/phenomena occurring over the cylinder surface. Class representatives (proxies) could then be used as generators of instantaneous pressure signals for the rest of class members, by means of transformations consistent with the variation of statistical moments within each class considered.

It should be noted that if x is the vector for any of the 32 pressure time-series and a transformation $f(x) = \lambda x$ is applied, where λ is a real number, the mean and the RMS of λx respectively are $\text{mean}(\lambda x) = \lambda \text{mean}(x)$ and $\text{RMS}(\lambda x) = \lambda \text{RMS}(x)$. Working with pressure fluctuations it should be possible to generate time sequences for any other pressure tap within the same class by proper scaling with the second (RMS) moment. This simple transformation, which can be applied to generate instantaneous fluctuations of pressure signals, $M_{i,j}$, for any member location $j = 2, \dots, m$ of any class $i = 1, \dots, n$ from the instantaneous pressure fluctuations for each class representative or generator, $M_{i,1}$, can be expressed as,

$$M_{i,j} = M_{i,1} \cdot \text{RMS}(i, j) / \text{RMS}(i, 1); \quad i = 1, \dots, n; \quad j = 2, \dots, m \quad (2)$$

Eq. (2) facilitates the straightforward calculation of instantaneous pressure fluctuation time-series within any cluster of locations with similar pressure signals if the generator or proxy, $M_{i,1}$, is properly selected. Just adding the mean from the experimental pressure time-series to the generated fluctuation pressure time-series $M_{i,1}$, a completely pressure time-series is reconstructed. Since the procedure described above assures the correctness of the first two moments (mean and RMS), the generator should be chosen to account for variations in the skewness (s) and kurtosis (k) within the cluster considered to overcome the linear nature of eq. (2). The simplest approach, is to select the generator of each cluster i in eq. (2) as the class member with the pair $[s_j, k_j]_i$ that has the minimum average RMS distance to the $[s_j, k_j]_i$ pairs for the rest of class members. This emphasizes the distribution of skewness and kurtosis when Eq. (2) is applied to generate pressure signals within each class.

4. Results and discussion

4.1 Classification and pressure forecasting

Sensor (locations) were clustered by k-means clustering algorithm (Hartigan and Wong, 1979) using the three dimensioned vectors (rms, skewness and kurtosis) obtained with a 20x20 SOM with a toroidal configuration to minimize border effects in the mapping.

This dimension yielded the classification in terms of quantization error and map continuity. A wide range of number of clusters was tested, selecting those with a low Davies-Bouldin Index (Davis and Bouldin, 1979), which is a function of the ratio of the sum of within-cluster scatter to between-cluster separation. Table 1 shows some of the selected clusterizations, including the one chosen as the most suitable (Table 1.3). Each table shows the number of populated clusters, listing which tap is the generator ($j=1$), and the ones that are generated by it ($j=2,\dots,n$). The remaining taps for each clusterization, are the ones that are a class by themselves (single-class taps). For example, in Table 1.1, 7 populated classes are created, and there are two taps that are a class by themselves (nos. 3 and 24). The sum of them, 9, is the number of clusters formed.

The generators given in columns $j=1$ of Table 1 were selected according to the procedure described in subsection 3.2 which takes into consideration the skewness (s_j) and kurtosis (k_j) of all sensors in each cluster j . The application of Eq. (2) to the classes given in Table 1 resulted in a new set of pressure data for the listed class members. The pressure sets formed by the single-class taps, the generated taps ($j=2,\dots,n$) and the generator taps ($j=1$) in Table 1 are used to calculate the instantaneous and average lift and drag coefficients. These sets, which contain a 72%, 47%, 31% and 22%, for Table 2.1, 2.2, 2.3 and 2.4 respectively, of information generated by Eq. (2), are identified thereafter as P_{LT} .

The distribution of the skewness and kurtosis corresponding to the experimental pressure signals and those generated (P_{LT}) with Eq. (8) for the class member locations listed in Table 1 are respectively depicted in Figs. 3a and 3b. Deviations decrease from a mean absolute error of 0.078 for skewness, using 9 clusters, to 0.051 using 22 clusters, across the 0.057 mean absolute error using 17 clusters and ends rising to 0.065 using 25 clusters. The same behavior is shown by the kurtosis, with mean absolute errors of 0.495, 0.497, 0.323 and 0.433 using 9, 17, 22 and 25 clusters respectively. This results point out that a too tight clusterization (25 clusters) decrease the capacity of generalization while a too wide one, let an excessive number of taps to be generated, some of them not enough similar to their generators. Being the classification using 17 clusters the optimum one, its mean absolute errors for skewness and kurtosis shows a good agreement between the four moments of the experimental pressure time-series and the generated ones (should be remembered that the mean and the RMS of the generated pressure time-series have the same value as the experimental ones due the transformation done in subsection 3.2). This is more so when the predicted RMS of time-fluctuations values for drag and lift coefficients are considered. Table 2 shows that there is good agreement with the experimental RMS of time-fluctuations values for lift and drag for P_{LT} using 22 clusters, with relative errors of 9.0% and 1.7% respectively. The selected classification (Table 1.3) evidences again a better agreement with experimental RMS of time-fluctuations value for lift, and almost for drag than the other classifications. As the number of taps generated (more clusters) decrease, the

RMS of time-fluctuations relative error decrease too, as it is logically, due the increase of experimental data used in the calculation of lift and drag coefficients. In spite of this fact, the 22 cluster classification improves the 25 cluster classification in lift coefficient terms and obtains a similar value in drag terms. Like in the calculation of the four statistical moments, the mean values of lift and drag coefficients are the same as the experimental ones due to the linear transformation done in subsection 3.2 to obtain the estimated pressure time-series (P_{LT}). Fig. 4 shows the autospectra, using Welch's method (Welch, 1967), of the experimental and generated pressure time series for the selected classification (Table 1.3). It can be seen that for most of the taps, experimental and generated autospectras are almost superposed, indicating the preservation of the turbulent flow dynamics.

Applying the methodology described in section 3, a good tap classification can be obtained as seen in the results described, but it can be improved doing a later analysis of the clusterization achieved. Discarding the generated taps that increase the mean absolute errors of skewness and kurtosis and the RMS of time-fluctuations of lift and drag coefficients, a finer classification is achieved. Table 3, shows the 22 clusters classification without three of its generated taps, that were the ones that more contributed in the error of the parameters estimated. This classification diminishes the mean absolute error for skewness and kurtosis to 0.038 and 0.311, respectively (Table 4.1) and to 1.47% and 0.09% for the relative error for RMS of time-fluctuations of lift and drag coefficients (Table 4.2). The post clustering analysis classification increases the accuracy of the global 32 taps pressure time-series system in all the parameters but diminishes the number of taps generated, from 31% to 22% in this case. The requirement of a big reduction in taps density or a high accuracy in skewness and kurtosis of the pressure time-series generated, and in the RMS of time-fluctuations of lift and drag coefficients, can point out if a reduction of generated taps is necessary and how severe it should be.

4.2 Additional tests

Once the methodology developed have shown a good performance, two new sets of data have been tested to check if it also works in different wind velocity conditions. Carried in the same conditions, but wind velocity, as described in section 2, the new data sets were obtained under an uniform velocity $U = 13.8$ m/s and $U = 6.5$ m/s, so that the Reynolds number was $Re = 4.5 \times 10^5$ and $Re = 2.2 \times 10^5$ respectively. Due to turbulence intensity (5%), both sets are in the supercritical flow regime in terms of drag coefficient (Cheung and Melbourne, 1983).

To facilitate the comparison between sets, the same total number of generated taps is selected; for $Re = 1 \times 10^6$ set, 22 clusters classification obtained the best results and this

correspond to a 10 of 32 generated taps (31%), so this is the total number of generated taps used in the new sets.

For $Re = 2.2 \times 10^5$, classification shown in Table 5.1 is obtained. The distribution of the skewness and kurtosis corresponding to the experimental pressure signals and those generated (P_{LT}) with Eq. (8) for the class member locations listed in Table 5.1 are respectively depicted in Figs. 5a and 5b, achieving a mean absolute error of 0.092 for skewness and 3.27 for kurtosis. Table 5.2 shows the mean and RMS of time-fluctuations value for lift and drag coefficients using the experimental pressure signals and those generated (P_{LT}) attaining a relative error of 2.75 % and 11.4% respectively.

For $Re = 4.5 \times 10^5$, classification shown in Table 6.1 is obtained. The distribution of the skewness and kurtosis corresponding to the experimental pressure signals and those generated (P_{LT}) with Eq. (8) for the class member locations listed in Table 6.1 are respectively depicted in Figs. 6a and 6b, achieving a mean absolute error of 0.072 for skewness and 1.11 for kurtosis. Table 6.2 shows the mean and RMS of time-fluctuations value for lift and drag coefficients using the experimental pressure signals and those generated (P_{LT}) attaining a relative error of 3.85 % and 1.94% respectively.

Fig. 7 and Fig. 8 show the autospectra of the experimental and generated pressure time series for both new sets of data classifications, illustrating the preservation of the turbulent behavior in the generated taps, as its autospectra almost superpose the experimental ones.

5. Conclusions

The application of Self-Organizing Maps (SOM) in classifying pressure sensors was observed to be successful. Representative locations for each sensor class were identified and used as proxies to generate pressure time-series that achieve a good agreement with the experimental ones. The promising results could be applied in the calculation of wind loads from a reduced set of data or, in the other hand, in the sensor density reduction on experimental sets. It can be concluded that this approach is able to apprehend the complexity of a high turbulent flow in terms of wind loads with only the four statistical moments of the pressure time-series.

Acknowledgments

The current study was supported by the grants FIS2005-07194 (MEC, Spain) and 2005SGR 00735 (DURSI, Generalitat de Catalunya). Francesc Giralt acknowledges the Distinguished Researcher Award, Generalitat de Catalunya. Computing support was provided by SHARCNET, as well as by the Senior Visiting Fellowship held by J. Ferrer-Gener, during the portion of the work carried out in Canada. G.A. Kopp gratefully acknowledges the support of the Canada Research Chairs Program. The

authors would also like to thank Dr. Jon Galsworthy for providing the experimental data.

References

Beltzer, A.I., Sato T., 2003. Neural classification of finite elements. *Computers and Structures*. 81, 2331-2335.

Cheung, C.K., Melbourne, W.H., 1983. Turbulence effect on some aerodynamic parameters of a circular cylinder at supercritical Reynolds numbers. *J. Wind Eng. Industr. Aerodynam.* 14, 399-410.

Davies, D.L., Bouldin, D.W., 1979. A Cluster Separation Measure. *IEEE Transactions on Pattern Analysis and Machine Learning*, 1(2).

Flood, I., Kartam, N., 1994. Neural networks in civil engineering. I: Principles and understanding. *J. Comp. Civ. Eng.* 8, 131-148.

Galsworthy, J., 2000. Aspects of across-wind loads and effects on large reinforced concrete chimneys. PhD thesis, University of Western Ontario, Canada.

Hartigan, J. A., Wong, M. A., 1979. A K-Means Clustering Algorithm, *Applied Statistics*. 28, No. 1, 100-108.

Haykin, S., 1994. *Neural Networks: a Comprehensive Foundation*. Macmillan Publishing, New York.

Ho, T.C.E., Surry, D., Morrish, D., Kopp, G.A., 2005. The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 1. Archiving format and basic aerodynamic data. *J. Wind Eng. Ind. Aerodyn.* 93, 1-30.

Hush, D.R., Horne, B.G., 1993. Progress in supervised neural networks: what is new since lippmann?, *IEEE Signal Process. Mag.* 10, 8-39.

Kangas J. A., Kohonen, T.K., Laaksonen, J.T., 1990. Variants of self-organizing maps. *IEEE Trans. Neural Network.* 1, 93-99

Kaski, S., Lagus, K., 1996. Comparing Self-Organizing Maps. In C. von der Malsburg, W. von Seelen, J. C. Vorbruggen, and B. Sendho (Eds.), *Proc ICANN96. International Conference on Artificial Neural Networks. Lecture Notes in Computer Science*. 1112, 809-814.

Kaski, S., 1997. *Data Exploration Using Self-Organizing Maps*. Dissertation for the degree of Doctor of Technology, Helsinki University of Technology, Espoo.

Kiviluoto, K., 1996. Topology Preservation in Self-Organizing Maps. Proceedings of International Conference on Neural Networks (ICNN), 294-299.

Kohonen, T., 1997. Self-Organizing Maps. Series in Information Sciences, **30**. Springer, Heidelberg.

Kopp, G.A., Chen, Y., 2006. Database-Assisted Design of Low-Rise Buildings: Aerodynamic Considerations for a Practical Interpolation Scheme. J. Struct. Eng. 132, Issue 6, 909-917.

Laine, S., 2003. Using visualization, variable selection and feature extraction to learn from industrial data. Dissertation for the degree of Doctor of Technology, Helsinki University of Technology, Espoo.

St. Pierre, L.M., Kopp, G.A., Surry, D., Ho, T.C.E., 2005, The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 2. Comparison of data with wind load provisions. J. Wind Eng. Ind. Aerodyn. 93, 31-59.

Welch, P.D., 1967. The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. IEEE Trans. Audio Electroacoustics. 15, 70-73.

Table 1. Clustering of cylinder pressure data ($Re = 1 \times 10^6$) expressed in terms of the second, third and fourth moments with a 20x20 SOM with a toroidal configuration using (1) 9 clusters, (2) 17 clusters, (3) 22 clusters and (4) 25 clusters.

		(1)	9 clusters	
		i	Generators (j=1)	Class Members (j=2,...,n)
Populated clusters	1	1	26	9
	2	2	10	25
	3	3	31	1, 5, 32
	4	4	2	4, 6, 29
	5	5	30	7, 8, 17, 27, 28
	6	6	22	11, 12, 13, 14, 16, 21, 23
	7	7	20	15, 18, 19

		(2)	17 clusters	
		i	Generators (j=1)	Class Members (j=2,...,n)
Populated clusters	1	1	32	1
	2	2	4	2
	3	3	5	31
	4	4	29	6
	5	5	26	9
	6	6	11	12
	7	7	30	7, 28
	8	8	16	13, 14
	9	9	20	15, 18, 19
	10	10	23	21, 22

		(3)	22 clusters	
		i	Generators (j=1)	Class Members (j=2,...,n)
Populated clusters	1	1	29	2
	2	2	5	31
	3	3	28	7
	4	4	11	12
	5	5	14	16
	6	6	20	15, 18, 19
	7	7	23	21, 22

		(4)	25 clusters	
		i	Generators (j=1)	Class Members (j=2,...,n)
Populated clusters	1	1	32	1
	2	2	5	31
	3	3	7	28
	4	4	26	9
	5	5	11	12
	6	6	20	19
	7	7	23	22

Table 2. Lift and drag coefficients predicted with the SOM generated pressure signals.

		Experimental	P _{LT} 9 clusters	P _{LT} 17 clusters	P _{LT} 22 clusters	P _{LT} 25 clusters
Lift	Mean	0,1717	0,1717	0,1717	0,1717	0,1717
	RMS	0,1475	0,0360	0,1114	0,1342	0,1208
Drag	Mean	0,5113	0,5113	0,5113	0,5113	0,5113
	RMS	0,0558	0,0931	0,0667	0,0567	0,0565

Table 3. Clustering of cylinder pressure data ($Re = 1 \times 10^6$) expressed in terms of the second, third and fourth moments with a 20x20 SOM with a toroidal configuration after a post clustering analysis of 22 clusters classification.

		i	Generators (j=1)	Class Members (j=2,...,n)
Populated clusters	1	1	11	12
	2	2	14	16
	3	3	29	2
	4	4	20	15, 18
	5	5	23	21, 22

Table 4. Results obtained for the classification illustrated on Table 3. (1) Skewness and kurtosis value for the estimated taps and (2) Lift and drag coefficients for the whole cylinder.

(1)	skewness			kurtosis		
Tap	Experimental	P _{LT}	Absolute error	Experimental	P _{LT}	Absolute error
#2	0,008	-0,043	0,051	7,891	7,571	0,320
#12	-0,337	-0,369	0,032	3,563	3,663	0,100
#15	-0,694	-0,699	0,005	4,569	4,986	0,417
#16	-0,378	-0,434	0,057	3,989	3,688	0,301
#18	-0,726	-0,699	0,027	5,402	4,986	0,416
#21	-0,505	-0,466	0,039	4,264	3,784	0,480
#22	-0,412	-0,466	0,054	3,640	3,784	0,144
Mean			0,038			0,311

(2)		Experimental	P _{LT}
Lift	Mean	0,1717	0,1717
	RMS	0,1475	0,1454
Drag	Mean	0,5113	0,5113
	RMS	0,0558	0,0557

Table 5. (1) Clustering of cylinder pressure data ($Re = 2.2 \times 10^5$) expressed in terms of the second, third and fourth moments with a 20x20 SOM with a toroidal configuration using 22 clusters, and (2) lift and drag coefficients for the whole cylinder.

(1)		22 clusters	
Populated clusters	i	Generators (j=1)	Class Members (j=2,...,n)
	1	11	17
	2	14	20
	3	25	26
	4	32	29
	5	9	16, 18
	6	19	23, 24
	7	13	12, 10

		(2)	Experimental	P_{LT}
Lift	Mean		0,0422	0,0422
	RMS		0,3348	0,3440
Drag	Mean		0,2927	0,2927
	RMS		0,2840	0,3166

Table 6. (1) Clustering of cylinder pressure data ($Re = 4.5 \times 10^5$) expressed in terms of the second, third and fourth moments with a 20x20 SOM with a toroidal configuration using 22 clusters, and (2) lift and drag coefficients for the whole cylinder.

		(1)	22 clusters	
		i	Generators (j=1)	Class Members (j=2,...,n)
Populated clusters	1		27	1
	2		31	2
	3		13	3
	4		10	24
	5		21	22
	6		26	25
	7		19	6, 17
	8		18	15, 16

		(2)	Experimental	P_{LT}
Lift	Mean		0,0923	0,0923
	RMS		0,1075	0,1033
Drag	Mean		0,3864	0,3864
	RMS		0,0775	0,0790




Fig. 1. Definition sketch of the experimental set-up





Fig. 2. Sketch of SOM; Neighborhood of unit i with prototype vector $m_i = [m_{i1}, m_{i2}, \dots, m_{in}]$



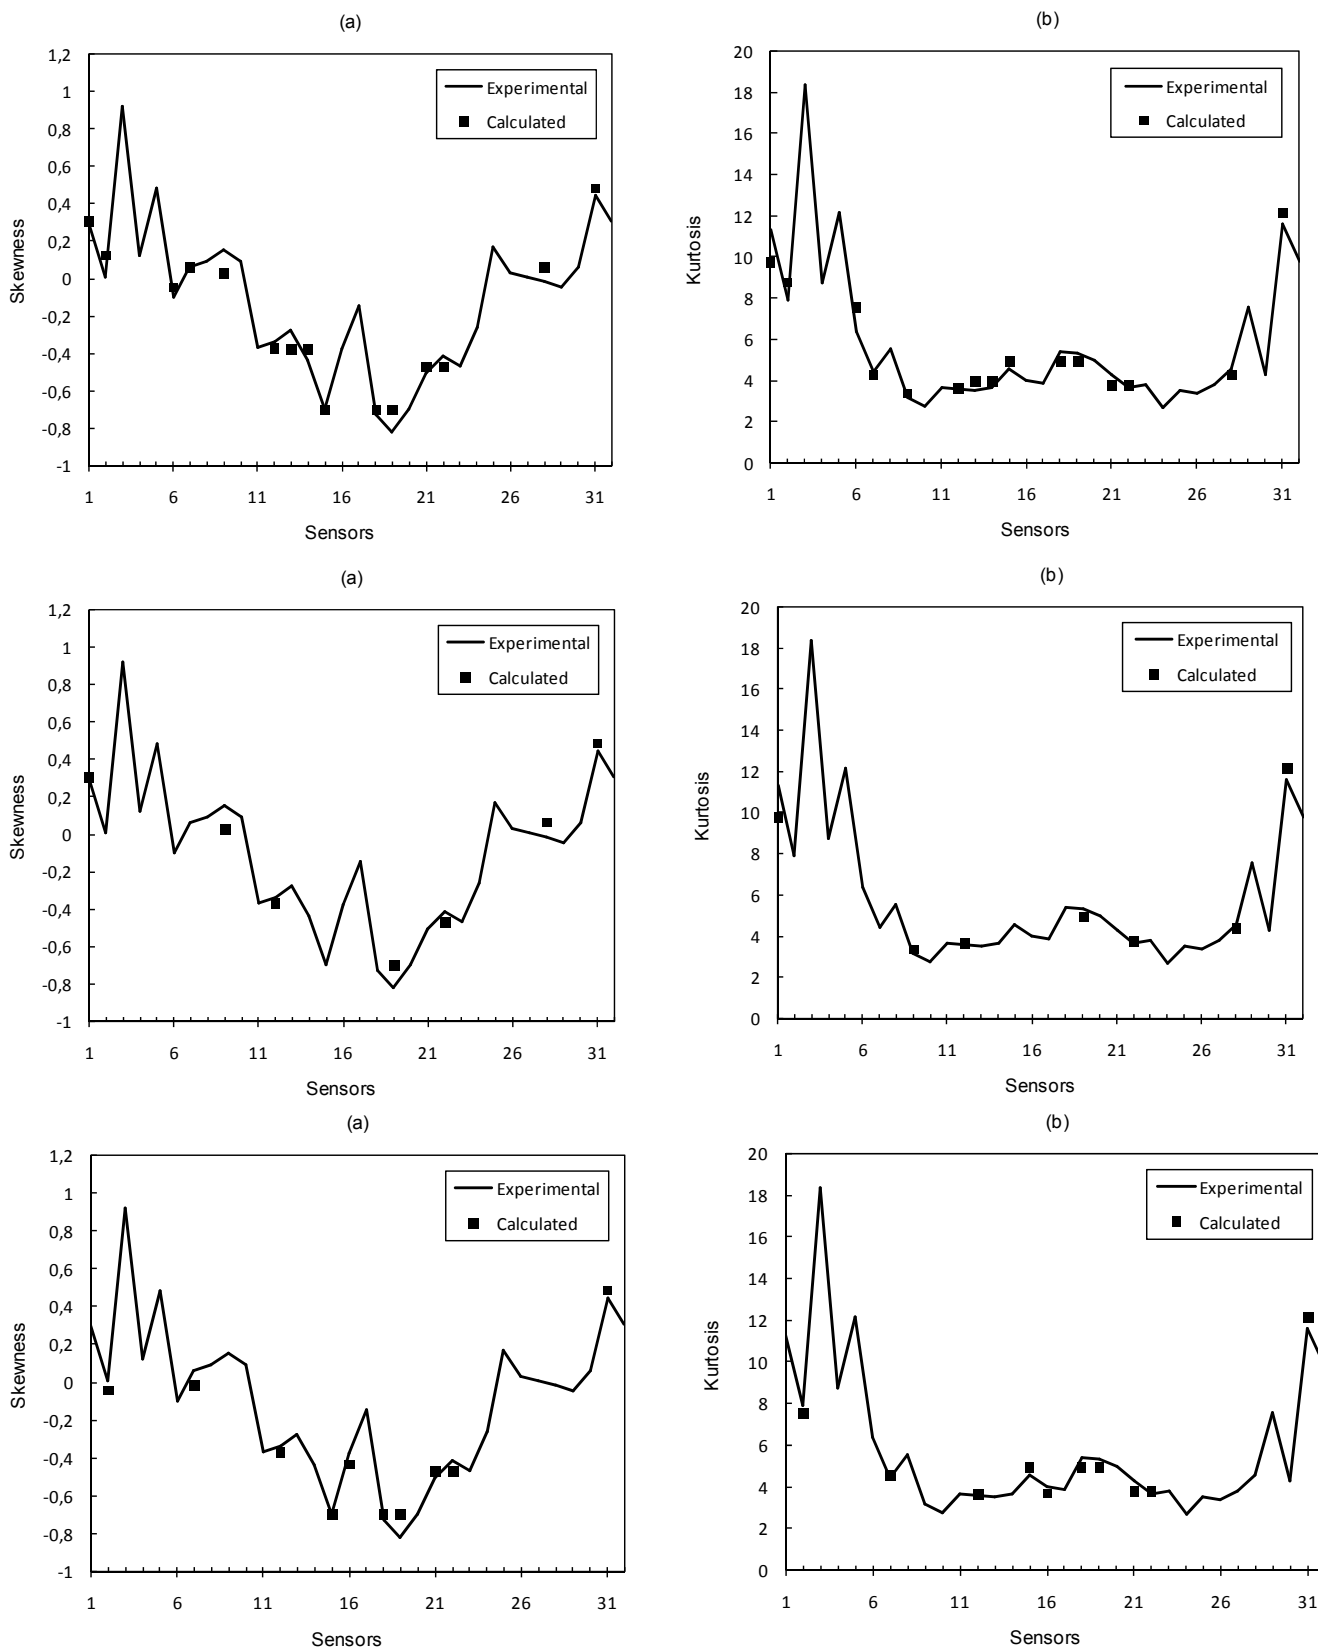










Fig. 3. Distribution of experimental and calculated (a) skewness and (b) kurtosis, with pressure taps classified according to (1) 9 clusters, (2) 17 clusters, (3) 22 clusters and (4) 25 clusters classification for $Re = 1 \times 10^6$.



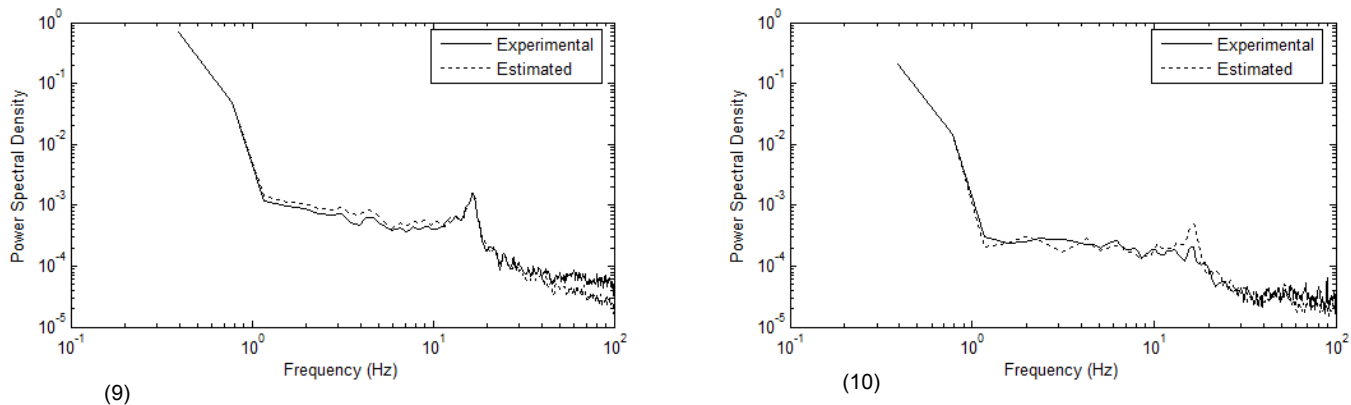


Fig. 4. Autospectra for the experimental and estimated pressure time series for the generated taps using Table 1.3 classification. (1) tap #2, (2) tap #7, (3) tap #12, (4) tap #15, (5) tap #16, (6) tap #18, (7) tap #19, (8) tap #21, (9) tap #22 and (10) tap #31.




Fig. 5. Distribution of experimental and calculated (a) skewness and (b) kurtosis, with pressure taps classified according 22 clusters classification for $Re=2.2 \times 10^5$.


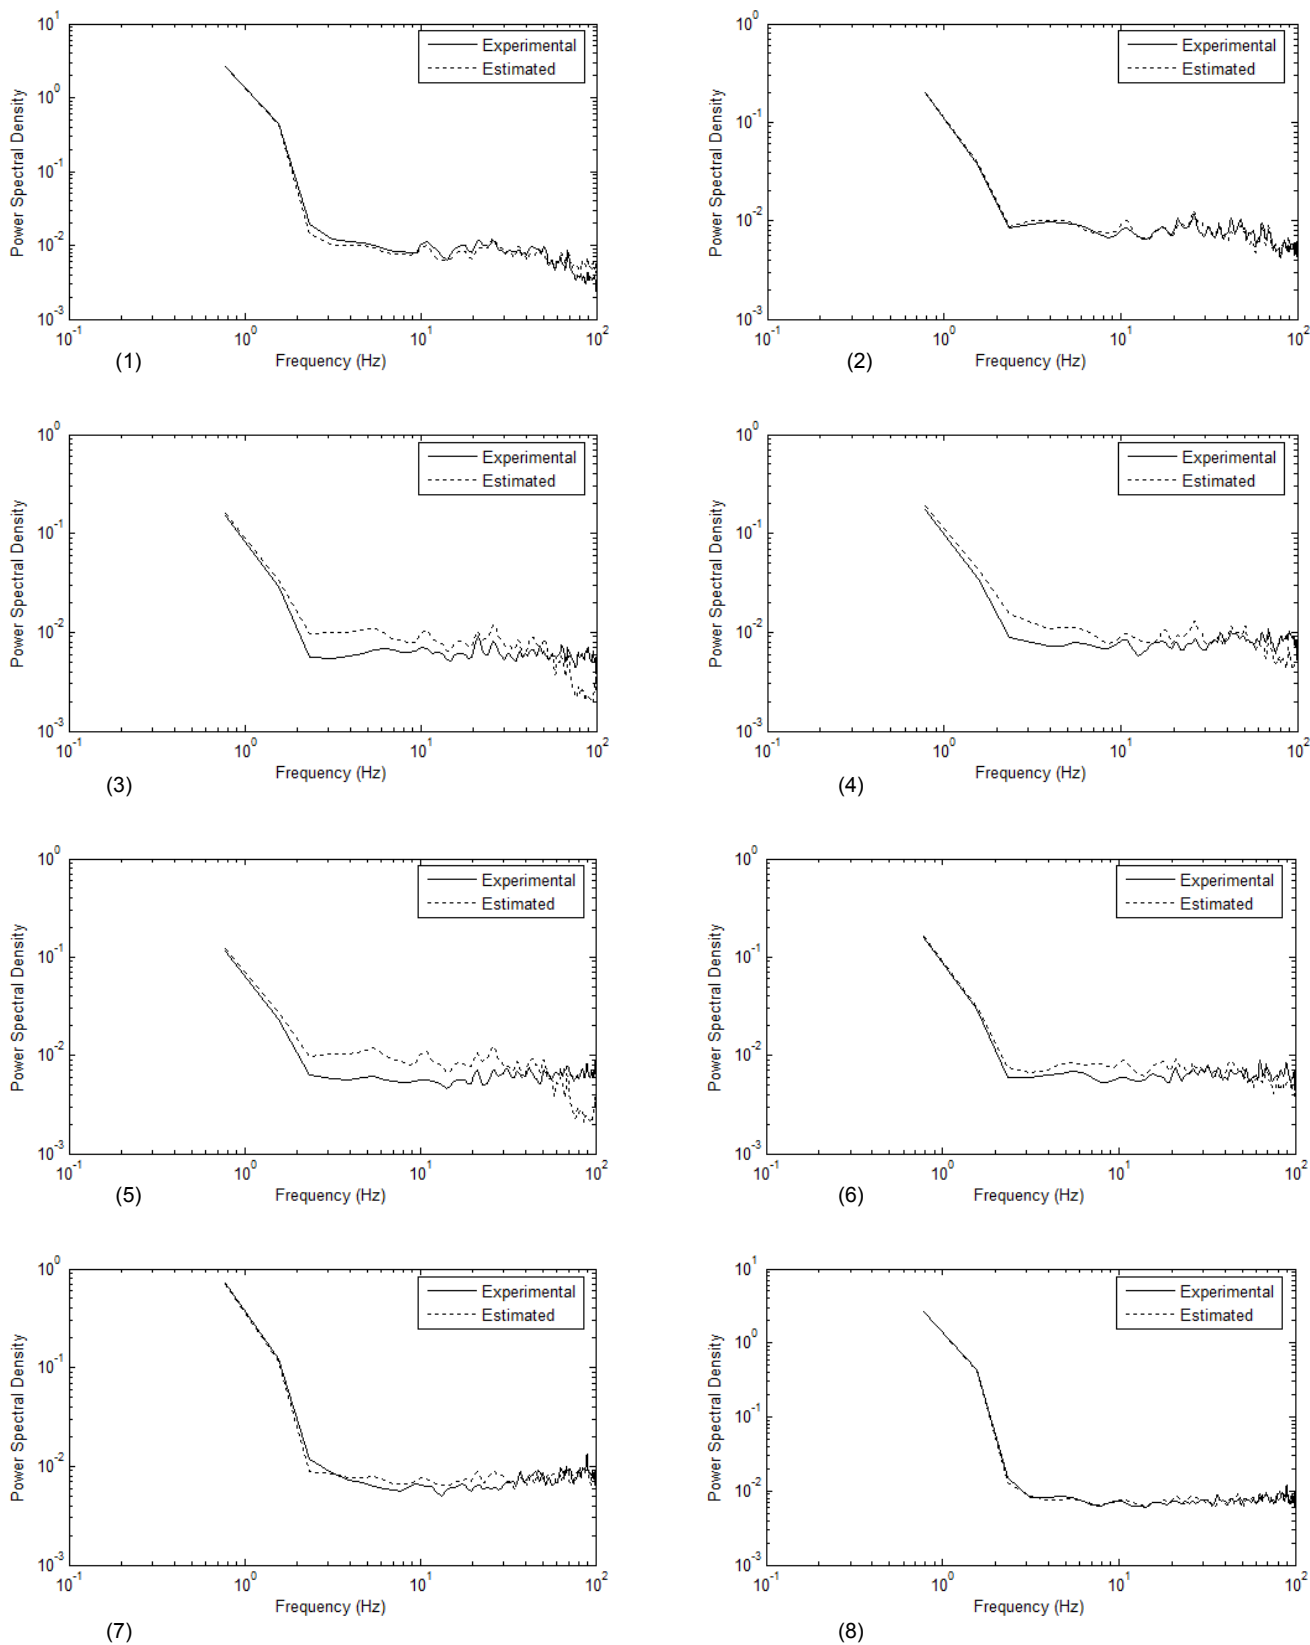


Fig. 6. Distribution of experimental and calculated (a) skewness and (b) kurtosis, with pressure taps classified according 22 clusters classification for $Re=2.2 \times 10^5$.













Fig. 7. Autospectra for the experimental and estimated pressure time series for the generated taps using Table 5.1 classification. (1) tap #10, (2) tap #12, (3) tap #16, (4) tap #17, (5) tap #18, (6) tap #20, (7) tap #23, (8) tap #24, (9) tap #26 and (10) tap #29.



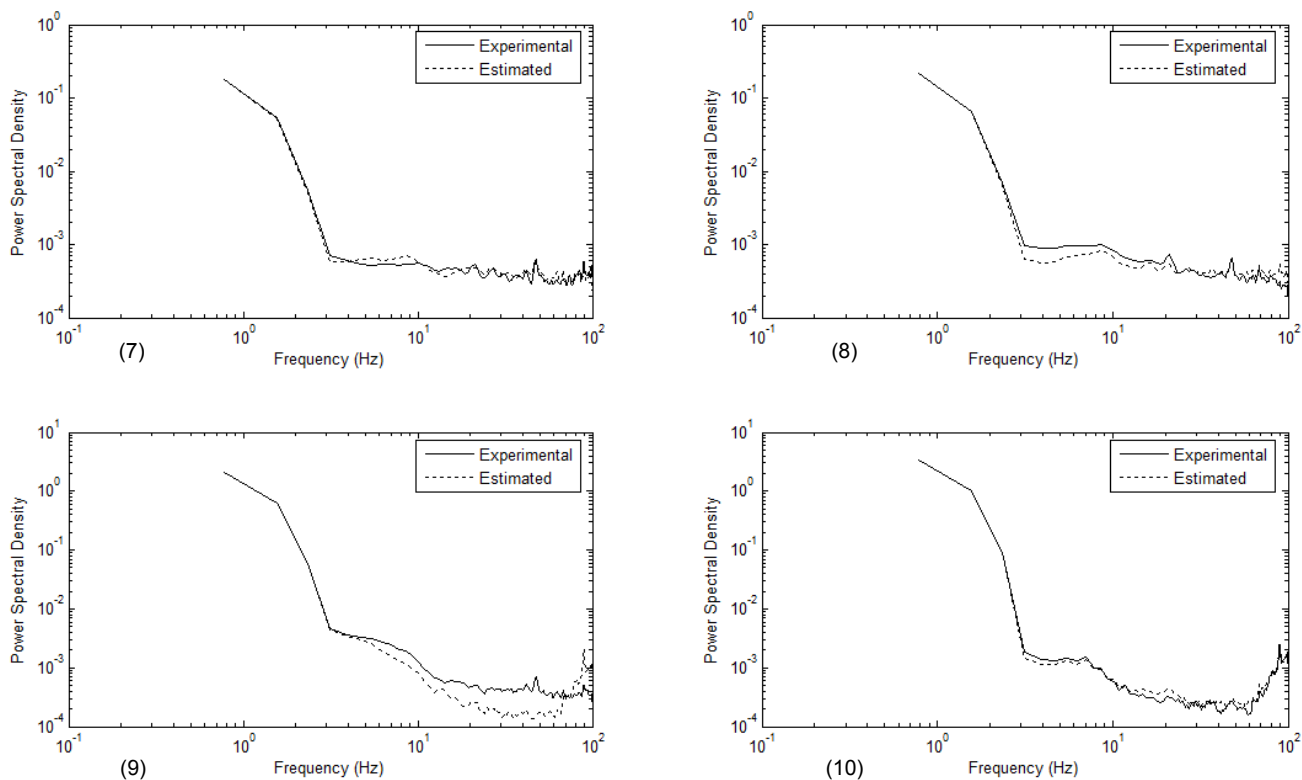


Fig. 8. Autospectra for the experimental and estimated pressure time series for the generated taps using Table 6.1 classification. (1) tap #1, (2) tap #2, (3) tap #3, (4) tap #6, (5) tap #15, (6) tap #16, (7) tap #17, (8) tap #22, (9) tap #24 and (10) tap #25.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Annex C

Interpolation of pressure coefficients for low-rise building
of different plan dimensions and roof slopes using
artificial neural networks.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

Interpolation of Pressure Coefficients for Low-Rise Buildings of Different Plan Dimensions and Roof Slopes using Artificial Neural Networks

X. Gavalda^{1a}, J. Ferrer-Gener^{1b}, Gregory A. Kopp², Francesc Giralt^{1a}

¹Grup de Fenomens de Transport, ^aDepartament d'Enginyeria Química, ^bDepartament d'Enginyeria Informàtica i Matemàtiques, Universitat Rovira i Virgili, 43007 Tarragona, Catalunya, Spain

²Boundary Layer Wind Tunnel Laboratory, Faculty of Engineering, University of Western Ontario, London, ON, N6A 5B9, Canada

Abstract

Database-assisted design (DAD) is emerging as an important tool to design buildings for wind effects. However, there is a need for robust interpolation methods for pressure coefficients in order to extend the range of conditions for the limited aerodynamic database cases characterized from wind tunnel experiments. An interpolation methodology was developed to include variable plan dimensions and roof slopes in the set of parameters considered in earlier studies for interpolation, thus improving predictions in the lee of the ridges of gable roofs.

Keywords: Database-Assisted Design; Artificial Neural Networks; Wind-induced pressures; Low-rise buildings; Aerodynamic loads.

1. Introduction

The current North American building codes (ASCE, 2005; NRCC, 2005) are based largely on wind tunnel experiments conducted at the University of Western Ontario in the late 1970s (Stathopoulos, 1979), where scale models of low-rise buildings were used to obtain pressure distributions. These tests covered a wide range of conditions including wind angle, upstream terrain roughness, roof slope and type, eave height, plan dimensions, etc. Since then, the state of technology has evolved, allowing the storage and distribution of the great quantities of data obtained from each experiment (Ho et al., 2005). This has led to the concept of Database-Assisted Design (DAD) for determining the wind loads and responses, with the intent of obtaining more risk-consistent, economical building designs (Rigato et al., 2001; Whalen, 1998; Simiu and Stathopoulos, 1997). However, the number of possible configurations that effect the

pressure distributions are significantly larger than any possible achievable database could store.

A key issue for the use of aerodynamic databases is the need efficient and accurate interpolation schemes (Kopp and Chen, 2006). In a sense, the key to the success of DAD is the ability to interpolate the existing archived pressure data to other building geometries for which no experimental data are available. The current study aims at expanding the capacity of previous interpolation schemes (Chen et al., 2003; Kopp and Chen, 2006) with the consideration of plan dimensions and roof slopes as input variables.

2. Experimental data

The experimental data analyzed herein are reported elsewhere (Ho et al., 2005). They are briefly summarized here for completeness. Wind tunnel experiments were carried out in the Boundary Layer Wind Tunnel II at the University of Western Ontario. Pressure time series were acquired via 1:100 scale models of gable-roofed, low-rise buildings, including three models of the same plan dimensions 80 ft x 125 ft (24.38 m x 38.10 m) for three roof slopes ($1/4:12$, $1:12$ and $3:12$) and three more models with different plan dimensions of 62.5 ft x 40 ft (19.1 m x 12.2 m), 250 ft x 160 ft (76.2 m x 48.8 m) and 187.5 ft x 120 ft (57.2 m x 36.6 m) with 1:12 roof slope. Several eave heights were measured, including the two heights examined herein, viz., 24 ft (7.3 m) and 40 ft (12.2 m).

Building dimensions and coordinate system for one of the models are shown in Fig. 1. In total, more than 300 pressure taps were placed on the roof surfaces and 19 approaching wind angles were measured in increments of 5° . One upstream terrain (open country, $z_o = 0.03\text{m}$) is used in the current analysis. The pressure signals were sampled at 500 Hz for 100 s and stored as pressure coefficients (C_p) with values relative to a reference height dynamic pressure. Many other details can be found in Ho et al. (2005), while analyses of the data can be found elsewhere (Chen et al., 2003; Kopp and Chen, 2006; St. Pierre et al., 2005; Oh et al., 2007).

3. Theoretical background

The ANN interpolation functions developed previously by the one of the authors (Chen et al., 2003) were used in the current study to predict time-averaged statistics (mean and standard deviation, rms) of pressure coefficients for more complex building parameters. These earlier ANN models were only able to interpolate for variable wind angles and roof heights, while the goal of the present work is to increase that capability to include roof slopes and plan dimensions. The ANN models employ feed-forward multilayer networks using a backpropagation training algorithm because of the proven

performance for functional approximations. Further details about backpropagation training algorithms can be obtained from many sources, such as Rumelhart et al. (1986). To obtain statistics (mean and rms) of simulated pressure time series, four three-layer feed-forward neural networks are employed. Due to limitations in the experimental database, two separate ANN models were employed, one for predicting coefficients for various plan dimensions and another for roof slopes. The reason for this is that there are only data for one set of plan dimensions with various roof slopes while, to develop a single ANN to predict both variables would require data where both roof slope and plan dimensions were varied.

Fig. 1 provides a sketch of the model building, defining all of the variables that were considered to be relevant to the flow dynamics in a single upstream terrain. These variables are building width (X) and length (Y), eave height (H), wind direction (α), roof slope (β) and the 3D roof coordinates (x , y , z). Since the plan dimension ratio (i.e., X/Y) for all buildings is constant, X and Y are dependent. Likewise, the eave height and z roof location are dependent too. The other variables are independent.

The performance of ANN models improves when they are trained with large and domain-consistent datasets. Nevertheless, the use of many dimensions and roof slopes as inputs into the ANN models would increase the complexity of the models. The normalization of roof locations, in such a way that incorporates the aerodynamics of the problem and reduces the span of pressure coefficients variations, is an important issue in the interpolation scheme. The models proposed by Kopp and Chen (2006) use the eave height (H) as the normalizing parameter because the largest loads on roofs are due to flow separations from the eaves edge for nearly flat roofs, and these are best normalized by H , as demonstrated by Lin et al. (1995) and Lin and Surry (1998). However, this choice has limitations when working with different plan dimensions in the same interpolation model due the effects of the ridge for higher slopes. For buildings of varying width, the ridge position also varies in terms of distance from the corner. This plays an important role in setting the pressure distribution on the leeward side of the ridge. Therefore, in the current work, the plan dimensions were adopted as the normalizing parameter for x and y roof coordinates to maintain the ridge position as an independent variable.

Once the normalizing parameter is chosen, the functional dependencies of the mean ($\bar{C}_{pi,est}$) and rms ($\tilde{C}_{pi,est}$) pressure coefficients at all locations i ($i = 1, 2, \dots, N$ and N is the number of taps) on a building with unknown values are,

$$\bar{C}_{pi,est} = f_1(x/X, y/Y, z, \alpha, X, Y) \quad (1)$$

$$\tilde{C}_{pi,est} = f_2(x/X, y/Y, z, \alpha, X, Y) \quad (2)$$

These functions, which are labeled as ANN model 1, account for varying roof plan dimensions. The corresponding model 2 functions for varying roof slopes are,

$$\bar{C}_{pi,est} = f_3(x/X, y/Y, z, \alpha, \beta) \quad (3)$$

$$\tilde{C}_{pi,est} = f_4(x/X, y/Y, z, \alpha, \beta) \quad (4)$$

Despite the fact that X and Y are dependent in this particular database, both variables were used to emphasize variations in plan dimensions. Building heights were characterized by the actual values of z instead of H because predictions improved (Gavalda, 2009).

4. Results

Three-layer, fully connected ANNs are capable of forming arbitrarily close approximations to any continuous nonlinear mapping (Haykin, 1994; Hush and Home, 1993). Therefore, this was the architecture chosen. Herein, we use the notation: i - h_1 - h_2 - o , where i are input variables, o are output variables and h_1 and h_2 are the hidden layers. Pearson's correlation coefficient (R) (Rodgers and Nicewander, 1988) between real mean ($\bar{C}_{pi,real}$) and rms ($\tilde{C}_{pi,real}$) pressure coefficients and those predicted by the ANNs was applied to evaluate model training performance. Tables 1-2 summarize the parameters of the ANN models. The training data for model 1 consisted in 118 data sets composed by the four different plan dimensions and the two different eave heights for all wind directions (except 280°, 300°, 320° and 340°, which are reserved as testing data), with a roof slope of 1:12. The training data for model 2 consisted in 90 data sets composed by the three different roof slopes and the two different eave heights for all wind directions (except 280°, 300°, 320° and 340°, which are reserved as testing data), with 80 ft x 125 ft (24.38 m x 38.10 m) roof plan dimensions.

Since the highest pressure gradients and rms values are near the leading corner, the leading tap was selected to check the prediction performance of the ANN for \bar{C}_p and \tilde{C}_p for single taps. Model 1 predicts \bar{C}_p and \tilde{C}_p for the four "unseen" wind angles (280°, 300°, 320° and 340°) with average absolute errors of 0.043 (5.6% average relative error) and 0.013 (4.2%), respectively. The corresponding average absolute errors for the predicted \bar{C}_p and \tilde{C}_p with model 2 respectively are 0.057 (8.2%) and 0.024 (7.7%).

The leading corner location was also used to evaluate model performances in terms of bay uplift. The mean corner bay uplift was well predicted by model 1 for 30 of the 32 data sets, with an average error of less than 3%. Model 1 was unable to keep this excellent forecasting performance for the two data sets corresponding to wind directions 300° and 320°, 24 ft (7.3 m) eave height, and 62.5 ft x 40 ft (19.1 m x 12.2 m) roof plan dimensions for which prediction errors increased to approximately 15% in absolute terms. Looking at Fig. 2, which presents the corner mean bay uplift for all data sets (training + predictions sets) corresponding to the 24 ft (7.3 m) eave height, one can observe that these two data sets do not follow the same tendency as the rest of data.

Since the ANN captures the global behavior of the system, it cannot predict exceptional patterns such as those followed by these two data sets in Fig. 2 and predictions are consistent with the trends of the rest of data sets, as it should be expected. The reason for this anomalous experimental behavior is not yet known; it could be due to an error during data storage, to data manipulation or to some other cause yet to be identified. If these two ‘outliers’ are not taken into account, the maximum relative error of predictions is 6.3%. The same behavior was found when the RMSEs (Root Mean Squared Errors) for the 120 pressure taps located in the corner bay were calculated with model 1. The average deviation for all 32 data sets is 2.4% for \bar{C}_p , while that for the two anomalous data sets is approximately 6% (almost three times the average value). If these two results were not taken into account, the maximum RMSE would be 3.2%. The average error for \tilde{C}_p is 1.0% with a maximum deviation of 1.8%. The mean corner bay uplift is also well predicted by model 2, with an average error of 2% for the 24 data sets considered in this case. The average RMSE for the predicted \bar{C}_p and \tilde{C}_p at all 120 pressure taps in the corner bay is less than 4.0% and 1.5%, respectively. These results indicate that the current ANN models are adequate to interpolate single tap pressure coefficients in gable-roofed buildings.

Figs 3 and 4 depict the experimental distributions of \bar{C}_p and \tilde{C}_p over the roof surface for two selected data sets together with the corresponding values predicted by model 1 (320°, roof height 40ft, roof plan 125’x80’) and model 2 (300°, roof slope 3:12, roof height 24ft), respectively. The predicted contour plots are in good agreement with the experimental data over the entire roof surface. Again, leading corner values are also well predicted by both current models. Another challenging area for model evaluation is the leeward ridge due to the slope change on the roof which causes an increase in suction pressures behind the ridge. The observed sharp pressure gradients along the leeward ridge were not predicted by previous models using the eave height (H) as the normalizing parameter (Chen et al., 2003). This problem is solved when using the roof plan dimensions as the normalizing parameter, as explained in Section 3.

To test models’ interpolation ability, new data sets with different (not “seen” before by the ANNs) roof plan dimensions (model 1) and roof slopes (model 2) were also generated. Fig. 2 depicts the experimental and model 1 predicted mean corner bay uplift versus wind direction for the 24 ft (7.3 m) roof eave height. Three new roof plan dimensions, 93.7 ft x 60 ft (28.6 m x 18.3 m), 156.2 ft x 100 ft (47.6 m x 30.5 m) and 218.7 ft x 140 ft (66.7 m x 42.7 m), were interpolated, as shown also in Fig. 2. Since there is no experimental data for these three interpolated cases, only tendencies can be examined and evaluated. The results in Fig. 2 indicate that the mean corner bay uplifts predicted for the three interpolated roof plan dimensions follow the trends of the experimental data determined for other similar building configurations.

Fig.5 depicts the experimental and model 2 predicted mean corner bay uplift versus wind direction for the 40 ft (12.2 m) roof eave height. Three new roof slopes were

interpolated (2:12, 5/2:12 and 11/4:12) with model 2 from the three “known” roof slopes (1/4:12, 1:12 and 3:12). The generalization (interpolation) ability of model 2 and the accuracy of the predictions are reasonable given the difficulty of capturing the effects of wind direction in the mean corner bay uplift. These effects were not properly accounted for in previous models (Chen et al., 2003; Kopp and Chen, 2006). Finally, Fig. 6 compares the contour plots of \bar{C}_p predicted for the 2:12 roof slope with the experimental contours of the 1:12 and 3:12 slopes for the same roof height and roof plan dimensions, and three wind directions of 270°, 315° and 360°. It can be seen that the behavior of the predicted \bar{C}_p contours for the 2:12 roof slope are in reasonable agreement with the experimental ones for the 1:12 and 3:12 roof slopes and for the three wind directions examined (270°, 315° and 360°).

5. Conclusions

The performance of previous interpolation models for pressure data over gable-roofed buildings has been improved by considering a new combination of alternative input variables (roof plan dimensions and roof slope) and normalizing method. Accurate predictions have been attained in (i) mean and rms pressure coefficients over the entire roof surface, even in challenging areas such as corner bay or leeward ridge, and (ii) mean corner bay uplift. Current results demonstrate that appropriate ANN architectures and input variables can model pressure data over gable-roofed buildings and increase the practical feasibility to interpolate within existing aerodynamic databases and expand their potential to design buildings for wind effects.

Acknowledgments

The current study was supported by the grants CTQ2006-08844 (MEC, Spain), FIS2005-07194 (MEC, Spain), 2005SGR-00735 and 2009SGR-01529 (DURSI, Generalitat de Catalunya). Francesc Giralt acknowledges the Distinguished Researcher Award, Generalitat de Catalunya. G.A. Kopp gratefully acknowledges the support of the Canada Research Chairs Program. This work was made possible by the facilities of the Shared Hierarchical Academic Research Computing Network (SHARCNET), as well as by the Senior Visiting Fellowship held by J. Ferrer-Gener during his visit to Canada.

References

American Society of Civil Engineers, 1999. ANSI/ASCE-98: Minimum Design Loads for Buildings and Other Structures. ASCE, New York.

American Society of Civil Engineers (ASCE), 2002. ASCE Standard, Minimum Design Loads for Buildings and Other Structures. ASCE 7-02, ASCE, Reston, VA, USA.

Chen, Y., Kopp, G.A., Surry, D., 2003. Prediction of pressure coefficients on roofs of low buildings using artificial neural networks. *J. Wind Eng. Ind. Aerodyn.* 91, 423-441.

Gavalda, X., 2009. Predicció de coeficients de pressió mitjançant xarxes neuronals artificials, Ph.D. Thesis. Universitat Rovira i Virgili, Tarragona, Spain.

Haykin, S., 1994. *Neural Networks: a Comprehensive Foundation*, Macmillan Publishing, New York

Ho, T.C.E., Surry, D., Morrish, D., Kopp, G.A., 2005. The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 1. Archiving format and basic aerodynamic data. *J. Wind Eng. Ind. Aerodyn.* 93, 1-30.

Hush, D.R., Horne, B.G., 1993. Progress in supervised neural networks: what is new since Lippmann? *IEEE Signal Process. Mag.* 10, 8-39.

Kopp, G.A., Chen, Y., 2006. Database-Assisted Design of Low-Rise Buildings: Aerodynamic Considerations for a Practical Interpolation Scheme. *J. Struct. Eng.* 132, Issue 6, 909-917.

Lin, J. X., Surry, D., Tieleman, H. W., 1995. The distribution of pressure near roof corners of flat roof low buildings. *J. Wind. Eng. Ind. Aerodyn.* 56, 235-265.

Lin, J. X., and Surry, D., 1998. The variation of peak loads with tributary area near corners on flat low building roofs. *J. Wind. Eng. Ind. Aerodyn.* 77-78, 185-196.

National Research Council Canada (NRCC), 1995. *National Building Code of Canada*. NRCC, Ottawa, Canada.

Rigato, A., Chang, P., Simiu, E., 2001. Database-assisted design, standardization and wind direction effects. *ASCE J. Struct. Eng.* 127, 855-860.

Rodgers, J. L., Nicewander, W. A., 1988. Thirteen Ways to Look at the Correlation Coefficient. *The American Statistician.* 42, 59-66.

Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning internal representations by error propagation, in: D.E. Rumelhart, J.L. McClelland (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. MIT Press, Cambridge, MA, 318-362.

Simiu, E., Stathopoulos, T., 1997. Codification of wind loads on low buildings using bluff body aerodynamics and climatological data base. *J. Wind Eng. Ind. Aerodyn.* 69-71, 497-506.

St. Pierre, L. M., Kopp, G.A., Surry, D., Ho, T.C.E., 2005, The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 2. Comparison of data with wind load provisions. *J. Wind Eng. Ind. Aerodyn.* 93, 31-59.

Stathopoulos, T., 1979. *Turbulent Wind Action on Low-rise Buildings*, Ph.D. Thesis. The University of Western Ontario, London, Ont., Canada.

Oh, J. H., Kopp, G.A., Inculet, D.R., 2007, The UWO contribution to the NIST aerodynamic database for wind loads on low buildings: Part 3. Internal pressures. *J. Wind Eng. Ind. Aerodyn.* 95, 755-779.

Whalen, T., Simiu, E., Harris, G., Lin, J., Surry, D., 1998. The use of aerodynamic databases for the effective estimation of wind effects in main wind-force resisting systems: application to low buildings. *J. Wind Eng. Ind. Aerodyn.* 77-78, 685-693.

Table 1. Parameters of the backpropagation ANN for model 1.

Inputs	$x/X, y/Y, z, \alpha, X, Y$
Output	\bar{C}_p or \tilde{C}_p
Architecture	6-21-30-1 for \bar{C}_p 6-26-24-1 for \tilde{C}_p
Transfer functions	Tangent sigmoid for hidden layers (h_1 and h_2) for \bar{C}_p Logarithmic sigmoid for hidden layers (h_1 and h_2) for \tilde{C}_p Linear for output layer (o) \bar{C}_p and \tilde{C}_p
Training algorithm	Levenberg-Marquardt backpropagation
Training epochs	425 for \bar{C}_p and 450 for \tilde{C}_p
Correlation coefficient (R)	0.994 for \bar{C}_p and 0.994 for \tilde{C}_p

Table 2. Parameters of the backpropagation ANN for model 2B.

Inputs	x, y, z, α, β
Output	\bar{C}_p or \tilde{C}_p
Architecture	5-20-22-1 for \bar{C}_p 5-19-20-1 for \tilde{C}_p
Transfer functions	Tangent sigmoid for hidden layers (h_1 and h_2) for \bar{C}_p Tangent sigmoid for h_1 and logarithmic sigmoid for h_2 for \tilde{C}_p Linear for output layer (o) \bar{C}_p and \tilde{C}_p
Training algorithm	Levenberg-Marquardt backpropagation
Training epochs	190 for \bar{C}_p and 250 for \tilde{C}_p
Correlation coefficient (R)	0.986 for \bar{C}_p and 0.988 for \tilde{C}_p

List of Figures

Fig. 1. Generic low building

Fig 2. Variation of the mean corner bay uplift versus wind directions for model 1 buildings. Comparison between experimental data (roof plans 62.5'x40'; 125'x80'; 187'x120'; 250'x160') and three new interpolated roof plans (93.75'x60', 156.25'x100'; 218.75'x140') for the 24 ft (7.3 m) roof height.

Fig. 3. Contours of \bar{C}_p for a wind direction of 320° at roof height 40 ft (12.19 m) and 125'x80' (38.1 m x 24.4 m) roof plan dimension using model 1: (a) experimental data and (b) ANN predictions.

Fig. 4. Contours of \tilde{C}_p for a wind direction of 300°, a roof slope of 3:12 and a roof height of 24 ft (7.3 m) using model 2: (a) experimental data and (b) ANN predictions.

Fig 5. Variation of the mean corner bay uplift versus wind directions for model 2 buildings. Comparison between experimental data (roof slopes 1/4:12; 1/12; 3/12) and three new interpolated roof slopes (2:12, 5/2:12; 11/4:12) for the 40 ft (12.19 m) roof height.

Fig. 6. Experimental (1:12 and 3:12 roof slopes) and model 2 predicted (2:12 roof slope) \bar{C}_p contours for a the 24 ft (7.3 m) roof height and wind directions: (a) 270°; (b) 315°; (c) 360°.




Fig. 1. Generic low building




Fig 2. Variation of the mean corner bay uplift versus wind directions for model 1 buildings. Comparison between experimental data (roof plans 62.5'x40'; 125'x80'; 187'x120'; 250'x160') and three new interpolated roof plans (93.75'x60', 156.25'x100'; 218.75'x140') for the 24 ft (7.3 m) roof height.




Fig. 3. Contours of \bar{C}_p for a wind direction of 320° at roof height 40 ft (12.19 m) and $125' \times 80'$ (38.1 m x 24.4 m) roof plan dimension using model 1: (a) experimental data and (b) ANN predictions.




Fig. 4. Contours of \tilde{C}_p for a wind direction of 300° , a roof slope of 3:12 and a roof height of 24 ft (7.3 m) using model 2: (a) experimental data and (b) ANN predictions.




Fig 5. Variation of the mean corner bay uplift versus wind directions for model 2 buildings. Comparison between experimental data (roof slopes 1/4:12; 1/12; 3/12) and three new interpolated roof slopes (2:12; 5/2:12; 11/4:12) for the 40 ft (12.19 m) roof height.

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

UNIVERSITAT ROVIRA I VIRGILI

PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS

Xavier Gavalda Sanromà

ISBN:978-84-693-3390-7/DL:T.999-2010

UNIVERSITAT ROVIRA I VIRGILI
PREDICCIÓ DE COEFICIENTS DE PRESSIÓ MITJANÇANT XARXES NEURONALS ARTIFICIALS
Xavier Gavalda Sanromà
ISBN:978-84-693-3390-7/DL:T.999-2010

Tarragona 2010