



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**

**ΤΜΗΜΑ ΟΙΚΟΝΟΜΙΚΩΝ ΕΠΙΣΤΗΜΩΝ**

**ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΟΙΚΟΝΟΜΙΚΗΣ  
ΦΥΣΙΚΗΣ**

**ΜΕΤΑΠΤΥΧΙΑΚΗ ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

***ΠΡΟΒΛΕΨΗ ΚΑΤΑΝΑΛΩΣΗΣ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ ΜΕ  
ΤΕΧΝΙΚΕΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ: ΕΦΑΡΜΟΓΗ ΣΤΗΝ  
ΕΛΛΑΔΑ***

ΟΝ/ΜΟ : Στεργίου Κωνσταντίνος  
ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ: κ. Θεόδωρος Καρακασίδης

## ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

<b>ΠΡΟΛΟΓΟΣ</b> .....	<b>4</b>
<b>ΠΕΡΙΛΗΨΗ</b> .....	<b>5</b>
<b>ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ</b> .....	<b>5</b>
<b>1 ΕΙΣΑΓΩΓΗ</b> .....	<b>6</b>
1.1 ΘΕΩΡΗΤΙΚΗ ΠΡΟΣΕΓΓΙΣΗ ΤΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ ΚΑΙ ΤΗΣ ΠΡΟΒΛΕΨΗΣ ΤΟΥ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ .....	6
1.2 ΠΑΡΑΓΟΝΤΕΣ ΠΟΥ ΕΠΗΡΕΑΖΟΥΝ ΣΗΜΑΝΤΙΚΑ ΤΟ ΦΟΡΤΙΟ .....	9
1.3 ΜΕΘΟΔΟΛΟΓΙΕΣ ΠΡΟΒΛΕΨΗΣ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ.....	10
<b>2 ΧΡΟΝΟΣΕΙΡΑ ΗΛΕΚΤΡΙΚΟΥ ΡΕΥΜΑΤΟΣ</b> .....	<b>14</b>
2.1 ΧΑΟΤΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΤΗΣ ΧΡΟΝΟΣΕΙΡΑΣ ΗΛΕΚΤΡΙΚΟΥ ΡΕΥΜΑΤΟΣ .....	14
2.2 ΕΚΘΕΤΗΣ LYARUNOV.....	15
<b>3 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ : ΒΑΣΙΚΕΣ ΑΡΧΕΣ</b> .....	<b>17</b>
3.1 Η ΑΡΧΗ .....	17
3.2 Η ΒΙΟΛΟΓΙΚΗ ΕΜΠΝΕΥΣΗ.....	18
3.3 ΣΥΝΑΡΤΗΣΕΙΣ ΕΝΕΡΓΟΠΟΙΗΣΗΣ .....	19
3.4 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ .....	21
3.5 ΛΕΙΤΟΥΡΓΙΑ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....	24
3.6 ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....	26
3.7 ΈΛΕΓΧΟΣ ΑΚΡΙΒΕΙΑΣ ΤΗΣ ΠΡΟΒΛΕΨΗΣ ΤΟΥ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΜΕΣΩ ΣΦΑΛΜΑΤΟΣ .....	26
3.8 ΕΦΑΡΜΟΓΕΣ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΚΑΙ ΠΛΕΟΝΕΚΤΗΜΑΤΑ.....	27
<b>4 ΝΕΥΡΩΝΙΚΑ ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ</b> .....	<b>29</b>
4.1 ΝΕΥΡΩΝΙΚΑ ΜΟΝΤΕΛΑ ΚΑΙ ΠΡΟΒΛΕΨΗ .....	29
4.2 Η ΜΕΘΟΔΟΣ ΤΗΣ ΒΑΘΙΑΣ ΕΚΜΑΘΗΣΗΣ (DEEP LEARNING Ή DL).....	34
<b>5 ΥΠΟΛΟΓΙΣΤΙΚΗ ΕΦΑΡΜΟΓΗ</b> .....	<b>36</b>
5.1 ΕΙΣΑΓΩΓΗ.....	36
5.2 ΔΕΔΟΜΕΝΑ .....	36
5.3 ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ ΠΡΟΣΘΙΑΣ ΤΡΟΦΟΔΟΤΗΣΗΣ ΕΝΟΣ ΕΠΙΠΕΔΟΥ – ΜΟΝΟΜΕΤΑΒΛΗΤΟ (FEED FORWARD NEURAL NETWORK) .....	37
5.4 ΕΠΑΝΑΛΗΠΤΙΚΟ ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ ΜΑΚΡΟΧΡΟΝΙΑΣ/ΒΡΑΧΥΧΡΟΝΙΑΣ ΜΝΗΜΗΣ ΕΝΟΣ ΕΠΙΠΕΔΟΥ - ΠΟΛΥΜΕΤΑΒΛΗΤΟ (RECURRENT NEURAL NETWORK – LONG SHORT TERM MEMORY) .....	42
5.5 ΝΕΥΡΩΝΙΚΟ ΔΙΚΤΥΟ LSTM ΠΟΛΛΑΠΛΩΝ ΚΡΥΦΩΝ ΕΠΙΠΕΔΩΝ - ΜΟΝΟΜΕΤΑΒΛΗΤΟ (MULTI LAYER LSTM).....	49
5.6 ΣΥΓΓΚΡΙΣΗ ΑΠΟΤΕΛΕΣΜΑΤΩΝ .....	52
<b>6 ΣΥΜΠΕΡΑΣΜΑΤΑ</b> .....	<b>55</b>
<b>7 ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ</b> .....	<b>55</b>

<b>ΒΙΒΛΙΟΓΡΑΦΙΑ</b> .....	<b>56</b>
<b>ΠΑΡΑΡΤΗΜΑ Α'</b> .....	<b>59</b>
ΔΕΔΟΜΕΝΑ .....	59

## ΠΡΟΛΟΓΟΣ

Η παρούσα διπλωματική εργασία εκπονήθηκε στα πλαίσια των σπουδών μου στο Μεταπτυχιακό Πρόγραμμα Σπουδών « Οικονομική Φυσική και Χρηματιστηριακές Προβλέψεις » του τμήματος Οικονομικών Επιστημών του Πανεπιστημίου Θεσσαλίας. Η έρευνα ξεκίνησε το Δεκέμβριο του 2018 και ολοκληρώθηκε τον Μάιο του 2019, υπό την επίβλεψη του κ. Θεόδωρου Καρακασίδη. Θα ήθελα να εκφράσω τις ευχαριστίες μου σε όσους συνέβαλαν στην όλη προσπάθεια μου. Αρχικά, τον επιβλέποντα Καθηγητή μου κ. Καρακασίδη Θεόδωρο, ο οποίος μου έδωσε την ευκαιρία να ασχοληθώ με ένα τόσο ενδιαφέρον αντικείμενο όπως την πρόβλεψη του ηλεκτρικού φορτίου εφαρμόζοντας τεχνικές νευρωνικών δικτύων και με την βοήθειά του, με την μορφή καθοδήγησης καθώς και με τις πολύτιμες συμβουλές του, δημιουργήθηκε ένα ισχυρό κλίμα συνεργασίας καθ' όλη την διάρκεια της εργασίας, και συνέβαλε στα μέγιστα για την ολοκλήρωσή της. Κυρίως όμως θέλω να αφιερώσω αυτή την εργασία στην οικογένεια μου η οποία με στήριξε όλα αυτά τα χρόνια στην υλοποίηση των προσωπικών μου στόχων όπως και, σε όλους τους κοντινούς μου ανθρώπους λόγω της κατανόησης που έδειξαν και της συμπαράστασης που πρόσφεραν σε όλη την φοιτητική μου πορεία.

## ΠΕΡΙΛΗΨΗ

Στην παρούσα μελέτη γίνεται εφαρμογή μεθοδολογίας για τη πρόβλεψη του ηλεκτρικού φορτίου στην Ελλάδα, δηλαδή η κατανάλωση ηλεκτρικής ενέργειας, με την χρήση μοντέλων νευρωνικών δικτύων. Σκοπός είναι η κατασκευή ενός μοντέλου που θα εξάγει προβλέψεις, για την χρονοσειρά της κατανάλωσης του ηλεκτρικού φορτίου στην Ελλάδα, αξιόπιστες με το μικρότερο δυνατό στατιστικό σφάλμα αφού η πρόβλεψη του ηλεκτρικού φορτίου σε μία αυξημένου κόστους αγορά ενέργειας, όπως η ελληνική, είναι μείζων σημασίας καθώς λανθασμένες προβλέψεις μπορούν να οδηγήσουν στην απώλεια μεγάλου όγκου χρηματικών ποσών. Όσον αφορά την εργασία αναπτύχθηκαν αλγόριθμοι εκμάθησης σε γλώσσα προγραμματισμού Python όπου τα νευρωνικά δίκτυα εκπαιδεύονται με ιστορικά δεδομένα και παράγονται προβλεπόμενες τιμές ηλεκτρικού φορτίου καθώς και στατιστικά σφάλματα αυτών. Το ευρύτερο αντικείμενο της εργασίας είναι η πρόβλεψη της κατανάλωσης ηλεκτρικού φορτίου στην Ελλάδα σε βραχυπρόθεσμο ορίζοντα με την χρήση μοντέλων νευρωνικών δικτύων καθώς και η επιλογή του καταλληλότερου μεταξύ αυτών για την δύσκολη διαδικασία της πρόβλεψης. Αναπτύσσονται μοντέλα νευρωνικών δικτύων δίνοντας έμφαση στα μοντέλα LSTM τα οποία εξάγουν προβλέψεις για χρονοσειρές ηλεκτρικής ενέργειας με πολύ μεγάλη ακρίβεια λόγω της πολυπλοκότητας τους. Η εφαρμογή γίνεται για δεδομένα του ελλαδικού χώρου όπου εκεί μπορεί να παρατηρηθεί η καινοτομία της διπλωματικής εργασίας διότι η εφαρμογή τέτοιων μοντέλων νευρωνικών δικτύων στη Ελλάδα δεν είναι ευρέως διαδεδομένη.

## ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ

Νευρωνικά Δίκτυα, Πρόβλεψη κατανάλωσης ηλεκτρικού φορτίου, Αλγόριθμοι εκμάθησης, Μοντέλα νευρωνικών δικτύων, Δίκτυα βαθιάς εκμάθησης, Τεχνητή νοημοσύνη, Βραχυπρόθεσμη πρόβλεψη, Ενεργειακή ζήτηση

# 1 ΕΙΣΑΓΩΓΗ

## 1.1 Θεωρητική προσέγγιση της ηλεκτρικής ενέργειας και της πρόβλεψης του ηλεκτρικού φορτίου

Το τέλος του 19<sup>ου</sup> αιώνα είναι η απαρχή της χρήσης ηλεκτρικής ενέργειας στις σύγχρονες κοινωνίες αμφισβητώντας ουσιαστικά την κυριαρχία πηγών ενέργειας στην βιομηχανική παραγωγή όπως ο ατμός και ο άνθρακας. Ο ηλεκτρισμός από αυτό το σημείο και έπειτα συνέβαλλε τα μέγιστα στην ανάπτυξη των κοινωνιών με την ανάπτυξη της τεχνολογίας σε ένα τεράστιο εύρος (μεταφορές, φωτισμός, θέρμανση, ηλεκτρικές συσκευές. Όπως καταλαβαίνουμε ο άνθρωπος και η κοινωνία πλέον είναι εξαρτημένοι από την ηλεκτρική ενέργεια κατά το μέγιστο βαθμό καθώς η ύπαρξή της είναι συνυφασμένη με την ορθή λειτουργία των κοινωνιών καθώς και την ομαλή διαβίωση σε αυτές.

Οι ευρωπαϊκές αγορές ηλεκτρικής ενέργειας λειτουργούν σε διάφορα επίπεδα (Erbach, 2016). Χωρίζονται σε αγορές χονδρικής και λιανικής οι οποίες εξυπηρετούν τους καταναλωτές ανάλογα με τις ανάγκες τους. Γενικώς, η ευρωπαϊκή αγορά ενέργειας αλλάζει δομή συνεχώς όπου αλλαγές και μετασχηματισμοί έχουν θέσει την αγορά σε μία νέα φάση (Καμμενάκης, 2017). Μπορούμε να διακρίνουμε τις αλλαγές αυτές σε τομείς της αγοράς όπως η παραγωγή, η διανομή και η διάθεση. Η πώληση ηλεκτρικής ενέργειας μέχρι πρόσφατα είχε την μορφή μονοπωλίου. Πλέον η τάση απελευθέρωσης των ενεργειακών αγορών σε παγκόσμιο επίπεδο οδηγούν στο πέρασμα από την φάση του μονοπωλίου σε αυτή του πλήρους ανταγωνισμού. Δηλαδή, ανεξάρτητες εταιρίες οι οποίες παράγουν ενέργεια και τροφοδοτούν είτε οργανισμούς είτε καταναλωτές απευθείας, εταιρίες οι οποίες διαχειρίζονται τα δίκτυα διανομής, εταιρίες λιανικής πώλησης οι οποίες αγοράζουν την ηλεκτρική ενέργεια από το δίκτυο παραγωγής (αγορά χονδρικής) και το μεταπουλούν σε μικρότερους καταναλωτές. Στην Ευρώπη η απελευθέρωση του ενεργειακού τομέα συνέβη αργότερα σε σχέση με άλλους τομείς της οικονομίας. Ως αποτέλεσμα αυτού, σε πολλές χώρες της Ευρωπαϊκής Ένωσης οργανισμοί μονοπωλίου κυριαρχούν διατηρώντας τις τιμές σε πολύ υψηλά επίπεδα δημιουργώντας δυσκολίες στην είσοδο νέων εταιριών στην αγορά. Στην Μεγάλη Βρετανία η παραγωγή ενέργειας στην δεκαετία του 1940 προερχόταν από τον άνθρακα σχεδόν εξ' ολοκλήρου. Με την ανάπτυξη του δικτύου από το 1948 ως το 1960 η κατανάλωση αυξήθηκε 150%. Η Μεγάλη Βρετανία κατάφερε στο πέρασμα των χρόνων να παραμείνει ανεξάρτητη ενεργειακά. Μετά τον Α' Παγκόσμιο πόλεμο στην Γερμανία δημόσιες επιχειρήσεις κοινής ωφέλειας και εταιρίες παροχής ενέργειας συνεργάστηκαν ώστε να υπάρξει ένας πιο σωστός καταμερισμός των εργασιών. Ως συνέπεια αυτού, μέχρι το 1998 υπήρχαν 8 μεγάλες εταιρίες παροχής ενέργειας στο δίκτυο αλλά και περίπου 80 μικρότερες. Η ηλεκτρική ενέργεια που προμηθευόταν οι καταναλωτές προερχόταν από τις 8 μεγάλες εταιρίες παροχής καθώς και από τις δημόσιες υπηρεσίες κοινής ωφέλειας σε ίσες ποσότητες. Στην Γαλλία τα πρώτα δίκτυα διανομής εμφανίζονται το 1884. Το 1940 γίνεται χρήση πυρηνικής ενέργειας για την παραγωγή ηλεκτρικού ρεύματος. Το 1973 η ηλεκτρική ενέργεια που παραγόταν από πυρηνική ενέργεια φτάνει τα 14 εκατομμύρια kW/h ανά έτος. Μέχρι το 1983 τα εργοστάσια

πυρηνικής ενέργειας παράγαν το 49% της ηλεκτρικής ενέργειας στην Γαλλία και ως το 1990 το 75%. Στην Ιταλία η ηλεκτρική ενέργεια γίνεται κρατική το 1962 μέσω της εταιρίας ENEL, όπου υπάρχει μονοπώλιο στην παραγωγή στην μεταφορά και την διανομή. Στην Ελλάδα και την Κύπρο η ανάπτυξη της αγοράς ενέργειας ξεκινάει με ραγδαίους ρυθμούς. Λίγο πριν το 1950 στην Ελλάδα υπάρχουν περίπου 400 εταιρίες παραγωγής ηλεκτρικής ενέργειας. Στην συνέχεια όμως με κρατική πρωτοβουλία δημιουργείται ένα κρατικό μονοπώλιο το οποίο απορρόφησε όλες τις υπάρχουσες εταιρίες. Το αποτέλεσμα είναι ότι σε κάποιες χώρες όπου η αγορά ενέργειας έχει απελευθερωθεί η τιμή της ηλεκτρικής ενέργειας (kW/h) είναι πιο χαμηλά σε σχέση με χώρες όπου ένας κρατικός φορέας ελέγχει όλη την αγορά όπως στην Ελλάδα όπου η τιμή του ηλεκτρικής ενέργειας είναι μία από τις υψηλότερες αν όχι η υψηλότερη στην Νοτιοανατολική Ευρώπη (Πρωτοπαπαδάκης, 2006). Στην Εικόνα 1 μπορούμε να παρατηρήσουμε την τιμή της ηλεκτρικής ενέργειας για τους οικιακούς όσο και για τους μη οικιακούς καταναλωτές στην Ευρωπαϊκή Ένωση για το δεύτερο μισό του 2017.



Εικόνα 1: Διάγραμμα τιμής ηλεκτρικής ενέργειας στην Ευρωπαϊκή Ένωση(ec.europa.eu/eurostat/statistics-explained).

Η λειτουργία των συστημάτων ηλεκτρικής ενέργειας απαιτεί τη συνεχή εποπτεία του ηλεκτρικού φορτίου σε μεγάλο εύρος χρονικών διαστημάτων για να είναι δυνατός ο έλεγχος και η οικονομικότερη λειτουργία του συστήματος (Σταματάκης, 2008). Το φορτίο παρουσιάζει μεταβολές οι οποίες σε μικρά χρονικά διαστήματα (δευτερόλεπτα) είναι μικρές και παρουσιάζουν τυχαιότητα δηλαδή έχουν την μορφή θορύβου. Ο Αυτόματος Έλεγχος Παραγωγής (ΑΕΠ) φροντίζει για την αντιστάθμιση της ζήτησης του φορτίου από την παραγωγή του συστήματος. Σε μεγαλύτερο εύρος χρόνου (λεπτά), οι διάφορες διακυμάνσεις του φορτίου είναι μεγαλύτερες και η Οικονομική Κατανομή Φορτίου είναι υπεύθυνη για την κατανομή του συνολικού φορτίου στο σύστημα, κατά τον πιο οικονομικό τρόπο, στις ήδη υπάρχουσες στο δίκτυο μονάδες. Σε χρονικά διαστήματα μεγαλύτερου εύρους (ώρες ή μέρες), οι μεταβολές που παρουσιάζει το φορτίο είναι μεγαλύτερης κλίμακας. Η κάλυψη του φορτίου για τέτοια διαστήματα χρόνου απαιτεί την έναρξη ή την διατήρηση μονάδων παραγωγής ή ανταλλαγή ισχύος με άλλα συστήματα ηλεκτρικής ενέργειας.

Τα κύρια μεγέθη που καθορίζουν την επάρκεια του συστήματος παραγωγής είναι ((ΑΔΜΗΕ, 2017):


- Η εξέλιξη του φορτίου
- Η διαθεσιμότητα μονάδων παραγωγής
- Η διαθεσιμότητα της ισχύος
- Οι μονάδες Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ)

Η διαθεσιμότητα των μονάδων παραγωγής αποτελεί την κρισιμότερη παράμετρο στην καταλληλότητα του συστήματος (ΑΔΜΗΕ, 2017). Τυχαίες βλάβες στο σύστημα έχουν επίπτωση στην καταλληλότητα του και ως αποτέλεσμα αυτού η μη διαθεσιμότητα των μονάδων παραγωγής λόγω τυχαίων βλαβών ελέγχεται μέσω της προσομοίωσης πιθανοτήτων στις μονάδες παραγωγής. Όσον αφορά τις υπόλοιπες παραμέτρους που επηρεάζουν την επάρκεια του συστήματος λόγω του στοχαστικού χαρακτήρα τους, η επίδραση τους εκτιμάται με την ανάλυση εναλλακτικών σεναρίων και υποθέσεων.

Η πρόβλεψη του ηλεκτρικού φορτίου αποτελεί μια βασική λειτουργία στα συστήματα ηλεκτρικής ενέργειας αφού αποτελεί ένα αγαθό καθώς και είδος εμπορίου. Κύριο χαρακτηριστικό του ηλεκτρισμού είναι ότι δεν μπορεί να αποθηκευτεί και ως συνέπεια αυτού, η πρόβλεψη του φορτίου είναι απαραίτητη για την διαχείριση της παραγωγής και της αγοράς σε ένα οικονομικό πλαίσιο. Στην Ελλάδα η αγορά ενέργειας απελευθερώθηκε το 2007, έτος το οποίο μπορεί να χαρακτηριστεί ως ορόσημο για τις ενεργειακές αγορές σε Ευρωπαϊκό επίπεδο, καθώς σε αυτό το διάστημα αναγνωρίστηκε το δικαίωμα επιλογής προμηθευτή για όλους τους καταναλωτές με εξαίρεση αυτούς που είναι εγκατεστημένοι σε Απομονωμένα Μικροδίκτυα (μη Διασυνδεδεμένα νησιά).

Όπως μπορούμε να παρατηρήσουμε στην Εικόνα 2 ο μέσος ετήσιος ρυθμός αύξησης της συνολικής καθαρής ζήτησης στη δεκαετία από το 2000 ως το 2010 ήταν 2.17% ο οποίος αν συγκριθεί με ρυθμούς αύξησης προηγούμενων δεκαετιών είναι σημαντικά μειωμένος (ΑΔΜΗΕ, 2017). Ο ετήσιος ρυθμός αύξησης της συνολικής καθαρής ηλεκτρικής ενέργειας ήταν 3.39%. Όταν ξεκίνησε η οικονομική κρίση στην Ελλάδα, το 2008, η συνολική καθαρή ζήτηση στο Σύστημα ανήλθε στο ιστορικό μέγιστο των 56.3 TWh, με αύξηση 1.11% σε σύγκριση με το 2007. Το 2009 υπήρξε σημαντική μείωση της ζήτησης στο σύστημα κατά 5.01% σε σχέση με το 2008 η οποία οφείλεται στη μείωση της ζήτησης ενέργειας από την βιομηχανία. Από τότε ως και το 2016 παρατηρούμε μια καθοδική τάση στην συνολική καθαρή ζήτηση Ηλεκτρικής Ενέργειας. Πολλοί παράγοντες έχουν συντελέσει σε αυτό όπως π.χ. η διασπορά της παραγωγής λόγω φωτοβολταϊκών.





Εικόνα 2: Εξέλιξη της Συνολικής Καθαρής Ζήτησης Ηλεκτρικής Ενέργειας κατά την περίοδο 2000 – 2016 (ΑΔΜΗΕ)

Καταλαβαίνουμε επομένως ότι, η πρόβλεψη του ηλεκτρικού φορτίου δηλαδή, της ζήτησης ηλεκτρικής ενέργειας, είναι πολύ σημαντική για την καλύτερη διαχείριση ενός συστήματος ηλεκτρικής ενέργειας τεχνικά και οικονομικά. Ανάλογα με τον ορίζοντα πρόβλεψης χρονικά μπορούμε να διαχωρίσουμε τις προβλέψεις ως βραχυπρόθεσμες μεσοπρόθεσμες και μακροπρόθεσμες. Βραχυπρόθεσμες προβλέψεις αναφέρονται σε χρονικό ορίζοντα δευτερολέπτων λεπτών έως μιας εβδομάδα. Μεσοπρόθεσμες προβλέψεις αναφέρονται σε χρονικό ορίζοντα μηνών έως και 5 ετών. Ενώ, οι μακροπρόθεσμες προβλέψεις σε χρονικό ορίζοντα 5 έως 10 ετών.

## 1.2 Παράγοντες που επηρεάζουν σημαντικά το φορτίο

Η εκμετάλλευση του ηλεκτρικού φορτίου έχει πολλές συνιστώσες. Ένα σημαντικό μέρος του ηλεκτρισμού καταναλώνεται από την βιομηχανία. Επίσης χρησιμοποιείται από ιδιώτες με σκοπό την κάλυψη βασικών αναγκών όπως η θέρμανση, ο φωτισμός κ.α. Ένα άλλο σημαντικό μέρος χρησιμοποιείται από κοινωφελείς υπηρεσίες για τον φωτισμό δρόμων, συγκοινωνίες κ.α.

Μπορούμε να διακρίνουμε τους παράγοντες που επηρεάζουν το φορτίο στις εξής κατηγορίες (Fahad & Arbab, 2014):

- A) Οικονομικοί παράγοντες
- B) Χρονικοί παράγοντες
- Γ) Καιρικοί παράγοντες
- Δ) Τυχαίοι παράγοντες

Θα πρέπει η επίδραση όλων των παραπάνω παραγόντων να ληφθεί υπόψη κατά τη δημιουργία ενός μοντέλου πρόβλεψης του φορτίου. Η Οικονομία ως παράγοντας επίδρασης έχει σημαντικό ρόλο στη διαμόρφωση της ζήτησης ηλεκτρικής ενέργειας. Η ακμή ή η παρακμή του βιομηχανικού τομέα σε μια χώρα, η ανάπτυξη ή ο κορεσμός της αγοράς

ηλεκτρικών συσκευών, ο πρωτογενής τομέας και αλλαγές σε αυτόν και γενικά η Οικονομία, έχουν σοβαρή επίδραση στον ρυθμό αύξησης ή στον ρυθμό μείωσης του φορτίου στο Σύστημα. Ο χρόνος είναι ένας άλλος παράγοντας ο οποίος έχει σημαντικό ρόλο καθώς εποχιακές αλλαγές επιδρούν στο φορτίο, όπως επιδρούν και οι αλλαγές της ώρας μέσα στην μέρα ή η αλλαγή της από την χειμερινή περίοδο στην Θερινή. Οι εβδομαδιαία και η ημερήσια περιοδικότητα του φορτίου οφείλονται στην εργασία των ανθρώπων αλλά και στις άδειες τους από αυτή (Fahad & Arbab, 2014). Για παράδειγμα, τις ημέρες που αντιστοιχούν στο Σάββατο και την Κυριακή η ζήτηση του φορτίου είναι μειωμένη. Επιπλέον, ο Καιρός προκαλεί σημαντικές μεταβολές καθώς η θερμοκρασία έχει σημαντικότερη επίδραση στη διαμόρφωση του φορτίου. Η υγρασία, η βροχόπτωση ο άνεμος είναι παράγοντες που επίσης επηρεάζουν. Τέλος, παράγοντες όπως τυχαίες διαταραχές στη λειτουργία του συστήματος, οι οποίες δημιουργούνται από όλο το εύρος των καταναλωτών είτε αυτοί ανήκουν στην κατηγορία των μικρών (νοικοκυριά, δημοφιλή τηλεοπτικά προγράμματα κ.α.) είτε σε αυτή των μεγάλων (βιομηχανία), επηρεάζουν την λειτουργία του Συστήματος και προσθέτουν αβεβαιότητα στις προβλέψεις.

### 1.3 Μεθοδολογίες πρόβλεψης ηλεκτρικού φορτίου

Ο λόγος που η πρόβλεψη του φορτίου αποτελεί ένα μείζον θέμα στην βιβλιογραφία των συστημάτων ηλεκτρικής ενέργειας είναι ότι με την ραγδαία ανάπτυξη της τεχνολογίας και των ηλεκτρονικών υπολογιστών έχουν αναπτυχθεί ταυτόχρονα επιστημονικές καινοτομίες και μέθοδοι που μας φέρνουν πολύ κοντά στην επίλυση αυτού του προβλήματος όσον αφορά περιβάλλοντα πραγματικού χρόνου. Πολλές μέθοδοι έχουν εφαρμοστεί κατά καιρούς επιφέροντας αποτελέσματα ικανοποιητικά αλλά όχι με την συχνότητα που θα απαιτούσε ένα τέτοιου είδους πρόβλημα και ως αποτέλεσμα καμία δεν κατόρθωσε να καθιερωθεί. Η πρόβλεψη του ηλεκτρικού φορτίου σε οποιοδήποτε χρονικό εύρος είναι πολύ σημαντική. Σε βραχυχρόνιο ορίζοντα ενδιαφέρον παρουσιάζει το γεγονός πως αξιόπιστες προβλέψεις του ηλεκτρικού φορτίου παρέχουν χρήσιμη πληροφορία στους εμπλεκόμενους με τις αγορές και πωλήσεις ενέργειας στο χρηματιστήριο ενέργειας, όπου υποβάλλονται καθημερινά προσφορές είτε για πώληση είτε για αγορά ηλεκτρικής ενέργειας για την επόμενη μέρα. Γίνεται κατανοητό ότι, προβλέψεις οι οποίες μπορούν να ακολουθήσουν τις πραγματικές τιμές, με μικρό στατιστικό σφάλμα, δίνουν ένα μεγάλο πλεονέκτημα για τους ενδιαφερόμενους. Με αξιόπιστες προβλέψεις της κατανάλωσης του φορτίου σε μεσοπρόθεσμο και μακροπρόθεσμο ορίζοντα πρόβλεψης ο διαχειριστής του συστήματος θα είναι ικανός να αντισταθμίζει την ζήτηση του φορτίου καθώς και οι ιδιώτες, όπως εταιρίες παραγωγής ηλεκτρικής ενέργειας, θα μπορούν να χρησιμοποιούν την πληροφορία της πρόβλεψης προς δικό τους συμφέρον όπως για το χρονικό διάστημα στο οποίο συμφέρει περισσότερο η συντήρηση των πηγών παραγωγής τους. Προσεγγίσεις των τελευταίων ετών βασίζονται στις τεχνικές των αλγόριθμων εκμάθησης ή αλλιώς των νευρωνικών δικτύων λόγω της δυνατότητας τους στην εκμάθηση των ιδιοτήτων των ιστορικών δεδομένων φορτίου όπου σε άλλη περίπτωση απαιτεί μεγάλης δυσκολίας διαδικασίες. Παρακάτω παραθέτουμε μερικά άρθρα όπου εφαρμόζονται διάφορες μεθοδολογίες πρόβλεψης του ηλεκτρικού φορτίου στις οποίες θα αναφερθούμε εκτενέστερα σε παρακάτω κεφάλαια.

Ο Hong, et. al. (2010) παρουσιάζουν μια κλασική μεθοδολογία γραμμικής παλινδρόμησης τόσο για την ωριαία μοντελοποίηση, όσο για την πρόβλεψη της ζήτησης ηλεκτρικής ενέργειας στην αμερική και την διερεύνηση της αιτιότητας κατανάλωσής της. Ωριαίες τιμές μοντελοποιούνται ώστε να γίνει πρόβλεψη της ζήτησης για ορίζοντα τριών ετών για την Αμερική. Τα αποτελέσματα από τα μοντέλα γραμμικής παλινδρόμησης τα οποία εφαρμόζονται ξεκινούν από στατιστικό σφάλμα 12.7% και λαμβάνοντας υπόψη τις συσχετίσεις μεταξύ φορτίου και θερμοκρασίας το σφάλμα πρόβλεψης μειώνεται στο 5.2%.

Οι Hong, et. al. (2011) παρουσιάζουν ένα προτότυπο μοντέλο πολλαπλής γραμμικής παλινδρόμησης για την βραχυπρόθεσμη πρόβλεψη του ηλεκτρικού φορτίου στην Αμερική. Χρησιμοποιούνται ιστορικά δεδομένα 2 ετών (2005 – 2007) για να προβλεφθεί το ηλεκτρικό φορτίο για το 2008. Τα αποτελέσματα δεν φαίνεται να είναι ικανοποιητικά και αυτό διότι παράγονται από ένα παλιό μοντέλο το οποίο δεν μπορεί να συλλάβει συμπεριφορές όπως το φαινόμενο του Σαββατοκύριακου ή αυτό των διακοπών.

Οι Goia, et al. (2010) εξετάζουν την βραχυπρόθεσμη πρόβλεψη της αιχμής του ηλεκτρικού φορτίου σύμφωνα με τα στοιχεία ζήτησης θέρμανσης. Χρησιμοποιείται μια διαδικασία συσσωμάτωσης (clustering) για τις καμπύλες ημερήσιας επιβάρυνσης του φορτίου και στην συνέχεια σύμφωνα με τις ομάδες που δημιουργήθηκαν ορίζονται οικογένειες μοντέλων παλινδρόμησης. Τα μοντέλα παλινδρόμησης τα οποία εφαρμόζονται πραγματοποιούν προβλέψεις αλλά με μεγάλα σφάλματα.

Οι Barack και Sadech (2016) παρουσιάζουν ένα υβριδικό μοντέλο ARIMA (Auto Regressive Integrated Moving Average) – ANFIS (Adaptive Neuro Fuzzy Inference System). Γίνονται προβλέψεις κατανάλωσης ενέργειας για διάφορους χρονικούς ορίζοντες πρόβλεψης όπου, τα αποτελέσματα δείχνουν να είναι πιο ικανοποιητικά σε σχέση με τα απλά μοντέλα ARIMA και ANFIS.

Οι Voronin και Partanen (2013) αναπτύσσουν μία μεθοδολογία πρόβλεψης, των κανονικών τιμών καθώς και των τιμών αιχμής της ηλεκτρικής ενέργειας στην Φιλανδία, για μια μέρα μπροστά. Για τις κανονικές τιμές τις χρονοσειράς χρησιμοποιεί μια μίξη μεθόδων η οποία αποτελείται από μετασχηματισμούς wavelet, γραμμικής παλινδρόμησης κινητό μέσο όρο (ARIMA) και μη γραμμικών νευρωνικών δικτύων. Επίσης χρησιμοποιούνται τρεις απλές τεχνικές ομαδοποίησης για να βρεθεί η πιθανότητα ύπαρξης τιμής αιχμής. Στο άρθρο προτείνεται η εφαρμογή νευρωνικών δικτύων για την πρόβλεψη των τιμών αιχμής, δηλαδή για τις μεγάλες και απότομες μεταβολές της χρονοσειράς ηλεκτρικής ενέργειας με την χρήση νευρωνικών δικτύων καθώς και με μοντέλα παλινδρόμησης RVM (Relevance Vector Machines). Η προτεινόμενη μέθοδος παρέχει σημαντική βελτίωση στην ακρίβεια της πρόβλεψης των τιμών ενεργειακών αγορών.

Επίσης, στο άρθρο των Lago, et. al. (2018) γίνεται εφαρμογή μοντέλων βαθιάς εκμάθησης και κλασικών στατιστικών μοντέλων για την πρόβλεψη της τιμής ηλεκτρικής ενέργειας για μια μέρα μπροστά. Τα αποτελέσματα τους οδηγούν στο συμπέρασμα ότι τα μοντέλα βαθιάς εκμάθησης γενικά προσδίδουν μεγαλύτερη ακρίβεια σε σχέση με τα κλασικά στατιστικά μοντέλα στην πρόβλεψη του ηλεκτρικού φορτίου, οι κινητοί μέσοι όροι δεν βελτιώνουν την ακρίβεια πρόβλεψης.

Στο άρθρο του ο He (2017) παρουσιάζει ένα νευρωνικό δίκτυο βαθιάς εκμάθησης για την ωριαία πρόβλεψη του ηλεκτρικού φορτίου στην Βόρεια Κίνα όπου από τα αποτελέσματα αποδεικνύεται ότι η ακρίβεια του συγκεκριμένου μοντέλου έχει αυξηθεί περίπου 50%, σε σχέση με κλασικές γραμμικές μεθόδους.

Οι Papanakidis και Dragoumas (2016) στο άρθρο τους εφαρμόζουν τεχνητά μοντέλα νευρωνικών δικτύων (ANN) ή υβριδικά μοντέλα όπου γίνεται συνδυασμός νευρωνικών δικτύων (ANN) με αλγόριθμους συσσωμάτωσης (clustering algorithms) για την πρόβλεψη της τιμής ηλεκτρικής ενέργειας για μια μέρα μπροστά για 5 χώρες (Ελλάδα, Ιταλία, Ισπανία, Γερμανία, Ελβετία). Τα αποτελέσματα αποδεικνύουν ότι τα προτεινόμενα μοντέλα είναι ισχυρά εργαλεία πρόβλεψης για τις ανάγκες των συμμετεχόντων στην αγορά ενέργειας.

Οι Topalli και Erkmen (2003), παρουσιάζουν ένα υβριδικό μοντέλο νευρωνικού δικτύου για την πρόβλεψη μιας μέρας μπροστά της ζήτησης ηλεκτρικής ενέργειας στην Τουρκία. Τα αποτελέσματα δείχνουν πως η υβριδική μέθοδος παράγει ακριβέστερες προβλέψεις σε σχέση με ένα απλό νευρωνικό δίκτυο.

Οι Otavio et. al,(2004) παρουσιάζουν ένα μοντέλο νευρωνικού δικτύου για την ωριαία πρόβλεψη του ηλεκτρικού φορτίου στην Βραζιλία τις επόμενες 24 ώρες. Το μοντέλο νευρωνικού δικτύου είναι ικανό να προβλέψει με ακρίβεια το ηλεκτρικό φορτίο είτε για βραχυπρόθεσμο είτε για μακροπρόθεσμο ορίζοντα πρόβλεψης.

Οι Mandal et. al (2006) παρουσιάζουν ένα μοντέλο νευρωνικού δικτύου για την πρόβλεψη του ηλεκτρικού φορτίου στην Ιαπωνία από μια έως 6 ώρες μπροστά. Τα αποτελέσματα δείχνουν ότι το μοντέλο είναι αξιόπιστο στην πρόβλεψη του ηλεκτρικού φορτίου ακόμα και στις περιπτώσεις ξαφνικών καιρικών αλλαγών.

Καταλήγουμε λοιπόν στο συμπέρασμα, μέσω της ανασκόπησης στην βιβλιογραφία, πως η ακρίβεια στην πρόβλεψη της ηλεκτρικής ενέργειας είναι μεγαλύτερη κατά την εφαρμογή είτε μη γραμμικών μοντέλων νευρωνικών δικτύων είτε υβριδικών μοντέλων αποτελούμενα από συνδυασμούς μεθόδων. Η πρόβλεψη του ηλεκτρικού φορτίου παρουσιάζει μεγάλο ενδιαφέρον καθώς προβλέψεις μεγάλης ακρίβειας αποτελούν πολύ ισχυρά εργαλεία για τις ανάγκες των εταιριών παραγωγής ενέργειας, των προμηθευτών και είναι πολύς σημαντικές στην οικονομική βελτιστοποίηση και στην αύξηση της αξιοπιστίας και της ασφάλειας του συστήματος ηλεκτρικής ενέργειας (Kumar, Saini, 2016).

Γι αυτό το λόγο θα ασχοληθούμε στην παρούσα εργασία με την ημερήσια πρόβλεψη της κατανάλωσης του ηλεκτρικού φορτίου στην Ελλάδα με τεχνικές μηχανικής μάθησης και συγκεκριμένα νευρωνικών δικτύων δίνοντας έμφαση σε μοντέλα βραχυπρόθεσμης/μακροπρόθεσμης πρόβλεψης τα LSTM τα οποία πρόσφατα έχουν αρχίσει να χρησιμοποιούνται για την πρόβλεψη του ηλεκτρικού φορτίου παράγοντας προβλέψεις μεγάλης ακρίβειας (Bouktif, 2018).


Στόχος της εργασίας είναι να διερευνηθεί η ακρίβεια των μονομεταβλητών και πολυμεταβλητών μοντέλων νευρωνικών δικτύων στην πρόβλεψη τιμών. Παρακάτω στο

δεύτερο κεφάλαιο γίνεται μια θεωρητική προσέγγιση στην ανάλυση της χαοτικής συμπεριφοράς των χρονοσειρών ρεύματος. Στο τρίτο κεφάλαιο γίνεται μια αναφορά στα νευρωνικά δίκτυα και σε βασικά μέρη αυτών. Στο τέταρτο κεφάλαιο παρουσιάζονται μοντέλα νευρωνικών δικτύων τα οποία χρησιμοποιήθηκαν για την πρόβλεψη του ηλεκτρικού φορτίου σύμφωνα με την βιβλιογραφία ενώ στο πέμπτο κεφάλαιο παρουσιάζεται η υπολογιστική εφαρμογή των μοντέλων νευρωνικών δικτύων που κατασκευάσαμε για την πρόβλεψη του ηλεκτρικού φορτίου στην Ελλάδα εξάγονται αποτελέσματα και γίνεται σύγκριση και σχολιασμός αυτών. Στο έκτο κεφάλαιο παρουσιάζονται τα συμπεράσματα και στο έβδομο γίνεται μια πρόταση για μελλοντική έρευνα.

## 2 ΧΡΟΝΟΣΕΙΡΑ ΗΛΕΚΤΡΙΚΟΥ ΡΕΥΜΑΤΟΣ


### 2.1 Χαοτικά χαρακτηριστικά της χρονοσειράς ηλεκτρικού ρεύματος

Στην αγορά ηλεκτρικής ενέργειας η τιμή του ηλεκτρικού ρεύματος επηρεάζεται από πολλούς παράγοντες και παρουσιάζει πολύ περίπλοκα και ακανόνιστα φαινόμενα (Hongming, Xianzhong, 2003). Για να γίνουν αντιληπτά τα χαοτικά χαρακτηριστικά της τιμής ηλεκτρικής ενέργειας κατασκευάζεται ένας χώρος φάσης από τις χρονοσειρές των τιμών και εξάγονται τα χαρακτηριστικά των ελκυστών δηλαδή οι διαστάσεις συσχέτισης και οι εκθέτες Lyapunov. Τα αποτελέσματα δείχνουν την χαοτική συμπεριφορά της χρονοσειράς ρεύματος και ως αποτέλεσμα αυτού η χρησιμοποίηση επαναλαμβανόμενων νευρωνικών δικτύων (RNN), μια κατηγορία στην οποία ανοίκουν τα LSTM, είναι η βέλτιστη περίπτωση. Στην Εικόνα 3 μπορούμε να παρατηρήσουμε την χρονοσειρά της ωριαίας τιμής του ηλεκτρικού ρεύματος από 1 Δεκεμβρίου του 2001 έως 31 Μαΐου του ίδιου έτους για την αγορά της Νέας Αγγλίας στην Αμερική.



Εικόνα 3: Χρονοσειρά ηλεκτρικού ρεύματος για την Νέα Αγγλία στην Αμερική (Hongming, Xianzhong, 2003).

Το περιβάλλον της αγοράς ηλεκτρικής ενέργειας επηρεάζεται από πολλούς παράγοντες και για αυτό το λόγο παρουσιάζει αυτή τη χαοτική συμπεριφορά. Οι χρονοσειρές ζήτησης ηλεκτρικής ενέργειας εμφανίζουν συνήθως διακυμάνσεις που σχετίζονται με τις εποχές (εποχικότητα), την βιομηχανική ανάπτυξη, την μεταβολή της ζήτησης του φορτίου κατά την χειμερινή και θερινή περίοδο (Kumar, Saini, 2016). Τα χαρακτηριστικά ενός μη γραμμικού χαοτικού συστήματος είναι η μη περιοδικότητα η ευαισθησία στις αρχικές συνθήκες και η δυσκολία πρόβλεψης σε μακροχρόνιο ορίζοντα. Στην Εικόνα 4 μπορούμε να παρατηρήσουμε την χαοτική συμπεριφορά της χρονοσειράς ζήτησης ηλεκτρικού φορτίου για το Δελχί.



Εικόνα 4: Χρονοσειρά ζήτησης ηλεκτρικού φορτίου στο Δελχί (Kumar, Saini, 2016).

## 2.2 Εκθέτης Lyapunov

Οι εκθέτες Lyapunov χρησιμεύουν στον διαχωρισμό των αρχικά κοντινών τροχιών. Είναι ουσιαστικά το μέτρο για την ύπαρξη χάους ή όχι. Ο μεγαλύτερος εκθέτης Lyapunov θα πρέπει να είναι ένας πεπερασμένος θετικός αριθμός για μια χαοτική διαδικασία και άπειρος αν η διαδικασία είναι στοχαστική (Kumar, Saini, 2016). Για τον υπολογισμό του χρησιμοποιείται η ανακατασκευή του χώρου φάσης, η οποία γίνεται με την τεχνική εμφύτευσης χρονικής καθυστέρησης (Τιφτσικτσόγλου, 2002). Για αυτό το λόγο η κατάλληλη τιμή για τον χρόνο καθυστέρησης (Time Delay) επιλέγεται ως το πρώτο ελάχιστο της συνάρτησης αμοιβαίας πληροφορίας (mutual information) επειδή σε αυτό το χρόνο η μέγιστη πληροφορία (εισέρχεται στην  $X_{t+}$  παρατήρηση από την  $X_t$ ). Όσον αφορά την διάσταση εμφύθισης (embedding dimension), η οποία είναι η μικρότερη διάσταση που απαιτείται για την ενσωμάτωση ενός χαοτικού ελκυστή ή η διάσταση όπου επαληθεύεται ο ντετερμινισμός, σε μια χρονοσειρά  $(x_1, x_2, \dots, x_n)$  το ανακατασκευασμένο διάνυσμα μπορεί να αναπαρασταθεί ως :

$$Y(m) = (x_i, x_{i+t}, \dots, x_{i+(m-1)t}) \text{ για } i = 1, 2, \dots, N \quad (1)$$

$$\text{όπου } N = n - (m - 1)\zeta \quad (2)$$

$m$  : Διάσταση εμφύθισης ( Embedding Dimension)

$\zeta$  : Καθυστέρηση ενσωμάτωσης

Εφόσον ανακατασκευάσουμε την χρονοσειρά χρησιμοποιώντας την διάσταση ενσωμάτωσης και τον χρόνο καθυστέρησης μπορούμε να προσδιορίσουμε τον μέγιστο εκθέτη Lyapunov από το σφάλμα πρόβλεψης σύμφωνα με την σχέση :

$$P(k) = \frac{1}{NT_s} \sum_{n=1}^N \log_2 \left( \frac{\|Y^{n+k} - Y^{nn+k}\|}{\|Y^n - Y^{nn}\|} \right) \quad (3)$$

$k$ : Αριθμός βημάτων χρόνου

$Y^{nn}$ : Ο πλησιέστερος γείτονας του  $Y^n$


$T_s$ : Ο χρόνος δειγματοληψίας

Η κλίση της καμπύλης του σφάλματος πρόβλεψης που σχεδιάστηκε έναντι του  $k$  (ενδιάμεσες τιμές) δίνει τον μέγιστο εκθέτη Lyapunov. Από τον σχέση:

$$\frac{1}{\lambda_{max}} \quad (4)$$

μπορούμε να πάρουμε τον μέγιστο ορίζοντα πρόβλεψης.

Στην Εικόνα 5 μπορούμε να παρατηρήσουμε τη γραφική παράσταση της αμοιβαίας πληροφορίας (mutual information) για την χρονοσειρά του Δελχί.



Εικόνα 5: Γραφική παράσταση αμοιβαίας πληροφορίας (mutual information) για την χρονοσειρά του Δελχί (Kumar, Saini, 2016).



## 3 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ : ΒΑΣΙΚΕΣ ΑΡΧΕΣ

### 3.1 Η αρχή

Ο νευροφυσιολόγος W. S. McCulloch και ο μαθηματικός W. Pitts το 1943 παρουσίασαν για πρώτη φορά το μοντέλο ενός νευρωνικού δικτύου (*McCulloch & Pitts, 1943*). Υποστηρίζανε ότι η δομή ενός τέτοιου μοντέλου αποτελείται από ένα σύνολο νευρώνων δείχνοντας την σύνδεση μεταξύ αυτών. «Αντιστοίχησαν» το μοντέλο του νευρωνικού δικτύου με ένα ηλεκτρικό κύκλωμα. Το 1947 οι δύο επιστήμονες σε ένα άρθρο τους παρουσιάζουν μια αναπτυγμένη μορφή του ίδιου μοντέλου νευρωνικού δικτύου το οποίο ως πλεονέκτημα της εξέλιξης του μπορεί να αναγνωρίζει σχήματα (*McCulloch & Pitts 1947*). Είναι ένα μοντέλο το οποίο θα αποτελέσει την βάση μετέπειτα σε νέα μοντέλα νευρωνικών δικτύων. Όσον αφορά το μοντέλο, η θεώρηση ήταν ότι ο νευρώνας μπορεί να λειτουργεί σε δύο καταστάσεις αυτή της ενεργοποίησης και αυτή της ηρεμίας. Η πληροφορία καθώς ρέει εντός του νευρώνα δέχεται έλεγχο από τις πύλες οι οποίες είναι είτε ενεργητικές (ενεργοποίησης), στέλνοντας σήμα, είτε παθητικές (ηρεμίας). Ένα ακόμα σημαντικό στοιχείο του νευρώνα έχει να κάνει με τις εισόδους και τις εξόδους του όπου, μπορεί να έχει διαφορετικές εισόδους αλλά μια μόνο έξοδο. Οι εξοδοί διαφορετικών νευρώνων απαγορεύεται να ενώνονται αλλά αναγκαστικά πρέπει να κατευθύνονται σε είσοδο διαφορετικού νευρώνα. Ο χρόνος των λειτουργιών είναι διακριτός και η απόκριση των νευρώνων γίνεται ταυτόχρονα. Για χρόνο  $t+1$  η κατάσταση του νευρώνα είναι εξαρτημένη από την κατάσταση αυτού σε χρόνο  $t$ . Η μνήμη σε αυτά τα δίκτυα είναι κλειστές διαδρομές του σήματος μέσα στο νευρωνικό δίκτυο. Υπό την έλλειψη παρουσίας κλειστών διαδρομών και καινούργιου σήματος το νευρωνικό δίκτυο θα παραμένει σε παθητική κατάσταση δηλαδή στην κατάσταση ηρεμίας. Μια γραμμή ενώνει την έξοδο με το σημείο εισόδου και κατ' αυτό τον τρόπο δημιουργείται ένας μηχανισμός ανάδρασης (feedback). Η ενεργοποίηση συνεχίζεται μέχρι να έλθει σήμα από ανασταλτική ίνα. Παλμοί εισέρχονται στην πύλη όπου και μεταδίδεται σήμα και πληροφορία. Ο J. Von Neumann χρησιμοποίησε την πληροφορία από τις εργασίες των McCulloch-Pitts σε υπολογιστές την δεκαετία του 1950 την εποχή όπου ο ηλεκτρονικός υπολογιστής διαδόθηκε ευρύτερα (*von Neumann, 1958*). Είναι το διάστημα όπου γίνονται οι πρώτες δοκιμές μετάβασης από τα βιολογικά νευρωνικά δίκτυα στα τεχνητά.

Επιστήμονες την εποχή εκείνη αρχίζουν να ασχολούνται με την λειτουργία των νευρωνικών δικτύων. Ο D. Hebb με το βιβλίο του *The Organisation of the Behaviour* εισάγει τον κανόνα μάθησης Hebb (*Hebb, 1949*) όπου γίνεται ανάλυση στις συνδέσεις των νευρώνων. Το νευρωνικό δίκτυο χρησιμοποιεί τις συνδέσεις μεταξύ των νευρώνων ώστε να κάνει εκμάθηση. Ο νευρώνας  $i$  συνεχώς διεγείρει τον νευρώνα  $j$  και ως αποτέλεσμα αναπτύσσεται μια σύνδεση όπου η απόδοση του φαινομένου αυξάνεται. Το βάρος μεταξύ των δύο νευρώνων ορίζεται ως  $w_{ij}$ , η είσοδος από τον  $i$  στον  $j$  ως  $x_i$  και  $y_i$  η έξοδος του  $i$  και η σύνδεση μεταξύ τους από τον τύπο:


$$w_{ij}(\text{new}) = w_{ij}(\text{old}) + a \cdot x_i \cdot x_j \quad (5)$$

a: θετική σταθερά, παράμετρος του ρυθμού εκπαίδευσης

### 3.2 Η βιολογική έμπνευση

Η έμπνευση για κάθε μορφής νευρωνικό δίκτυο ξεκινά από την βιολογία καθώς όλοι οι ζωντανοί οργανισμοί έχουν νευρικό σύστημα το οποίο είναι υπεύθυνο για λειτουργίες όπως η μνήμη ή η μάθηση ([keliphos.physics.auth.gr](http://keliphos.physics.auth.gr)). Η ανάπτυξη των νευρωνικών δικτύων ήρθε μέσα από έρευνες Τεχνητής Νοημοσύνης (Artificial Intelligence) δηλαδή, την αντιγραφή της αντοχής σε βλάβες και της γνώσης από βιολογικά νευρωνικά δίκτυα μέσω της μοντελοποίησης του εγκεφάλου. Τα νευρωνικά δίκτυα δεν λειτουργούν σειριακά αλλά με έναν τρόπο παράλληλο καθώς η πληροφορία χωρίζεται στους νευρώνες και είναι σαν να έχουμε ταυτόχρονα πολλές πηγές επεξεργασίας. Η σύνδεση μεταξύ δύο νευρώνων ονομάζεται σύναψη. Ο νευρώνας αποτελεί την πιο μικρή ανεξάρτητη μονάδα του δικτύου και επεξεργάζεται πληροφορίες λαμβάνοντας και στέλνοντας ηλεκτρικά σήματα σε άλλους νευρώνες. Καταλαβαίνουμε ότι οι πρώτες γνώσεις για τα νευρωνικά δίκτυα προέρχονται από την βιολογία.

Πρόσφατες έρευνες στην επιστήμη της επεξεργασίας δεδομένων, αποδεικνύουν την τεράστια ικανότητα του ανθρώπινου μυαλού να καταλήγει σε απλά σήματα εισόδων εξόδων από πολύπλοκα ερεθίσματα. Επομένως, από ένα τεράστιο αριθμό ιδιαίτερα απλών μονάδων εργασίας, ο εγκέφαλος κατορθώνει την εκτέλεση εξαιρετικά πολύπλοκων καθηκόντων. Τέλος μεγάλο ενδιαφέρον παρουσιάζει το γεγονός ότι τα τεχνητά νευρωνικά δίκτυα έχουν την ικανότητα να επιτύχουν τόσο αξιόλογα αποτελέσματα χρησιμοποιώντας ένα όχι τόσο πολύπλοκο μοντέλο όπως ο ανθρώπινος εγκέφαλος. Στην Εικόνα 6 μπορούμε να παρατηρήσουμε την βασική δομή ενός νευρώνα.



Εικόνα 6: Βασική δομή ενός νευρώνα ([el.wikipedia.org/wiki/Νευρώνας](http://el.wikipedia.org/wiki/Νευρώνας))

Στη δεκαετία του 90 η μηχανική μάθηση άρχισε να επηρεάζεται πολύ από την θεωρία των πιθανοτήτων και τη στατιστική. ([el.wikipedia.org/wiki/Τεχνητή\\_νοημοσύνη](http://el.wikipedia.org/wiki/Τεχνητή_νοημοσύνη)) Το μεγάλο πλεονέκτημα είναι ο μη περίπλοκος μαθηματικός σχηματισμός όπως επίσης δεν είναι τόσο απαραίτητος ο μεγάλος όγκος δεδομένων. Η εξέλιξη του κλάδου της τεχνητής νοημοσύνης έχει οδηγήσει σε επιτυχείς προβλέψεις βραχυπρόθεσμου ορίζοντα όσον αφορά το ηλεκτρικό φορτίο. Τα τεχνητά νευρωνικά δίκτυα τα οποία είναι ευρέως διαδεδομένα είναι τα Artificial Neural Networks (ANN) και τα οποία είναι εμπνευσμένα από τα

βιολογικά νευρωνικά δίκτυα. Τα μοντέλα νευρωνικών δικτύων αποτελούμενα από προγραμματισμένα στοιχεία τους νευρώνες οι οποίοι λειτουργούν παράλληλα. Η σύνδεση των νευρώνων γίνεται μέσω συνδετικών βαρών, τα οποία επιτρέπουν την προσαρμογή του μοντέλου μέσω μιας διαδικασίας εκμάθησης. Ουσιαστικά τα νευρωνικά δίκτυα είναι υπολογιστικά μοντέλα τα οποία έχουν την δυνατότητα αποθήκευσης γνώσης μέσω της εκμάθησης.

Η έρευνα σε αυτό το πεδίο λαμβάνει χώρα πολλές δεκαετίες όμως η μεγάλη ανάπτυξη συνέβει στις αρχές του 1980. Το πλεονέκτημα με τα απλά στατιστικά μοντέλα είναι ότι μπορούν να μοντελοποιήσουν ένα πολυδιάστατο πρόβλημα χωρίς την απαίτηση πολύπλοκων υποθέσεων μεταξύ των μεταβλητών εισόδου. Υπάρχει μεγάλο εύρος μοντέλων νευρωνικών δικτύων. Το κοινό τους χαρακτηριστικό είναι ότι όλα σχετίζονται με την ιδέα των βιολογικών νευρωνικών δικτύων. Πρακτικά, η δομή τους είναι νευρώνες οι οποίοι μπορούν να δέχονται  $n$  ( $x_1, x_2, \dots, x_n$ ) εισόδους και να εξάγουν μια έξοδο  $y$ . Επίσης χαρακτηρίζονται από μια πόλωση  $b$  (bias), η οποία μπορεί να είναι μη μηδενική ή μηδενική. Σε κάθε είσοδο  $x_n$  αντιστοιχεί ένα βάρος  $w_n$ , αντίστοιχα. Ο υπολογισμός της συνολικής εισόδου του νευρώνα γίνεται ως εξής:

$$z = w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b \quad (6)$$

Ενώ ο υπολογισμός της εξόδου  $y$  του νευρώνα:

$$y = f(z) = f(w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n + b) \quad (7)$$

$f$ : συνάρτηση ενεργοποίησης ή συνάρτηση μεταφοράς

### 3.3 Συναρτήσεις ενεργοποίησης

Η συνάρτηση ενεργοποίησης για το νευρωνικό δίκτυο μπορεί να είναι:


- Βηματική (step transfer function)
- Γραμμική (linear transfer function)
- Μη Γραμμική (non – linear transfer function)
- Στοχαστική (stochastic transfer function)

#### α) Βηματική Συνάρτηση

Η βηματική συνάρτηση ενεργοποίησης μπορεί να είναι η:

$$\varphi(x) \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (8)$$

ή οποιαδήποτε άλλη βηματική συνάρτηση.



Εικόνα 7: Βηματική συνάρτηση ενεργοποίησης ([el.wikipedia.org/wiki/Νευρώνας](http://el.wikipedia.org/wiki/Νευρώνας))


Το μειονέκτημα που παρουσιάζεται όταν χρησιμοποιούμε την βηματική συνάρτηση ως συνάρτηση ενεργοποίησης στα τεχνητά νευρωνικά δίκτυα είναι πως η παράγωγός της απειρίζεται. Ως αποτέλεσμα αυτού, δημιουργήθηκε η ανάγκη χρησιμοποίησης συναρτήσεων ενεργοποίησης των οποίων η γραφική παράσταση μοιάζει με την βηματική, αλλά είναι συνεχείς και παραγωγίσιμες σε όλο το πεδίο ορισμού τους. Ένα παράδειγμα τέτοιας συνάρτησης είναι η σιγμοειδής συνάρτηση.

## β) Γραμμική συνάρτηση

Η γραμμική συνάρτηση ενεργοποίησης μπορεί να είναι:

$$\varphi(x) = x \quad (9)$$

ή οποιαδήποτε άλλη γραμμική συνάρτηση.



Εικόνα 8: Γραφική παράσταση γραμμικής συνάρτησης ενεργοποίησης ([el.wikipedia.org/wiki/Νευρώνας](http://el.wikipedia.org/wiki/Νευρώνας))


## γ) Μη γραμμική συνάρτηση

Η μη γραμμική συνάρτηση ενεργοποίησης που χρησιμοποιείται στα νευρωνικά δίκτυα συχνά είναι η σιγμοειδής. Οι πιο γνωστές σιγμοειδής συναρτήσεις είναι οι εξής:

i) Λογιστική σιγμοειδής:  $\varphi(x) = \frac{1}{1+e^{-x}}$  (10)

ii) Υπερβολική εφαπτομένη:  $\varphi(x) = \tanh x$  (11)

Στην εικόνα 9 μπορούμε να παρατηρήσουμε την γραφική παράσταση σιγμοειδούς συνάρτησης.




Εικόνα 9: Γραφική παράσταση σιγμοειδούς συνάρτησης([el.wikipedia.org/wiki/Νευρώνας](http://el.wikipedia.org/wiki/Νευρώνας))

### 3.4 Αρχιτεκτονική Νευρωνικών Δικτύων

Το τεχνητό νευρωνικό δίκτυο ουσιαστικά είναι μια συλλογή νευρώνων οι οποίοι είναι συνδεδεμένοι μεταξύ τους (Σταματάκης, 2007). Τα νευρωνικά δίκτυα που είναι ευρέως γνωστά είναι αυτά των πολλών στρωμάτων και αποτελούνται από ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα καθώς και ένα επίπεδο εξόδου. Στο επίπεδο εισόδου οι νευρώνες στέλνουν σήμα μέσω των βαρών στο επίπεδο των κρυφών νευρώνων. Σε κάθε κρυμμένο νευρώνα πολλαπλασιάζεται η είσοδος με το βάρος της, προστίθενται τα γινόμενα και η πόλωση, ενώ το άθροισμα εισάγεται σε μια συνάρτηση ενεργοποίησης και στην συνέχεια περνάει στην έξοδο όπου έχουμε το αποτέλεσμα.

Στην εικόνα 10 μπορούμε να διακρίνουμε ένα νευρωνικό δίκτυο του οποίου η αρχιτεκτονική του είναι της μορφής 3 - 4 - 2 (οι αριθμοί νευρώνων στο στρώμα εισόδου, κρυμμένου στρώματος και στρώματος εξόδου αντίστοιχα).



Εικόνα 10: Νευρωνικό δίκτυο εμπρός τροφοδότησης, αρχιτεκτονικής 3 - 4 - 2 (bdounicon.ru)

Το νευρωνικό δίκτυο αποτελείται 12 συνδέσεις ( $3 \cdot 4 = 12$ ) μεταξύ της εισόδου και του κρυμμένου στρώματος, και από 8 ( $4 \cdot 2 = 8$ ) συνδέσεις μεταξύ του κρυμμένου στρώματος και της εξόδου το οποίο αθροιστικά είναι 20 διασυνδέσεις. Στην σύνδεση μεταξύ του νευρώνα στο στρώμα εισόδου και του νευρώνα στο κρυμμένο στρώμα καθώς και από αυτόν στην έξοδο αντιστοιχεί μια τιμή βάρους η οποία ενώνει τους δύο νευρώνες. Οι κρυφοί νευρώνες καθώς και οι νευρώνες της εξόδου αυτού του νευρωνικού δικτύου έχουν μηδενικές πολώσεις. Στους συγκεκριμένους νευρώνες χρησιμοποιείται μια συνάρτηση ενεργοποίησης (π.χ σιγμοειδής).

Η δομή των νευρώνων, εξαρτάται από τον αλγόριθμο που χρησιμοποιείται για την εκπαίδευση του. Τα δίκτυα τα οποία χαρακτηρίζονται ως εμπρός τροφοδότησης, η πληροφορία (σήμα) έχει κατεύθυνση από την είσοδο στην έξοδο. Ανάδραση λέμε ότι έχουμε όταν οι εξόδοι νευρώνων γίνονται είσοδοι σε νευρώνες προηγούμενων επιπέδων.

Μπορούμε να διακρίνουμε 4 κατηγορίες αρχιτεκτονικών δομών οι οποίες είναι οι εξής (Λιβιέρης, 2009):

#### A) Δίκτυα απλής τροφοδότησης (Feed Forward):


Δεν υπάρχουν συνδέσεις μεταξύ νευρώνων ενός επιπέδου με νευρώνες προηγούμενου επιπέδου.

##### i) Εμπρός τροφοδότησης ενός επιπέδου

Το απλούστερο νευρωνικό δίκτυο είναι ένα δίκτυο perceptron ενός επιπέδου, το οποίο αποτελείται μόνο από ένα στρώμα κόμβων εξόδου. Οι είσοδοι τροφοδοτούνται απευθείας στις εξόδους μέσω μιας σειράς βαρών.

##### ii) Εμπρός τροφοδότησης πολλαπλών επιπέδων

Αυτό το είδος δικτύων αποτελείται από πολλαπλά στρώματα υπολογιστικών μονάδων, συνήθως διασυνδεδεμένα με τρόπο προώθησης. Κάθε νευρώνας σε ένα στρώμα έχει κατευθύνει συνδέσεις με τους νευρώνες του επόμενου στρώματος. Σε πολλές εφαρμογές οι μονάδες αυτών των δικτύων χρησιμοποιούν ως συνάρτηση ενεργοποίησης την σιγμοειδή συνάρτηση. Η θεωρητική προσέγγιση αυτού το δικτύου είναι πως κάθε πληροφορία μπορεί να προσεγγιστεί στενά από ένα perceptron πολλαπλών στρώσεων με ένα κρυφό στρώμα. Χρησιμοποιώντας την πληροφορία ο αλγόριθμος προσαρμόζει τα βάρη κάθε σύνδεσης για να μειώσει το σφάλμα. Με την επανάληψη της διαδικασίας εκμάθησης σε πολλούς κύκλους το σφάλμα ελαχιστοποιείται. Σε αυτό το σημείο το δίκτυο έχει τελειώσει την εκμάθηση και έχει μάθει μια λειτουργία ενός στόχου.



Εικόνα 11: Απεικόνιση Νευρωνικού Δικτύου εμπρός τροφοδότησης ενός επιπέδου  
([en.wikipedia.org/Feedforward\\_neural\\_network](https://en.wikipedia.org/Feedforward_neural_network))


## Β) Δίκτυα με ανατροφοδότηση (Feedback ή Recurrent):

Υπάρχουν συνδέσεις μεταξύ νευρώνων ενός επιπέδου και νευρώνων προηγούμενου επιπέδου. Σε αυτή την κατηγορία ανοίκουν τα επαναλαμβανόμενα τεχνητά νευρωνικά δίκτυα ή Recurrent Neural Networks (RNN).

### i) Επαναλαμβανόμενα τεχνητά νευρωνικά δίκτυα (RNN)


Ένα επαναλαμβανόμενο νευρωνικό δίκτυο (RNN) είναι ένα είδος τεχνητού νευρικού δικτύου όπου οι συνδέσεις μεταξύ των κόμβων σχηματίζουν ένα κατευθυνόμενο γράφημα κατά μήκος μιας χρονικής αλληλουχίας ([medium.com](https://medium.com)). Αυτό του επιτρέπει να παρουσιάζει χρονική δυναμική συμπεριφορά. Σε αντίθεση με τα ανεστραμμένα ανεστραμμένα δίκτυα, τα RNNs μπορούν να χρησιμοποιούν την εσωτερική τους κατάσταση (μνήμη) για να επεξεργάζονται ακολουθίες εισόδων. Η λογική αυτού του είδους δικτύου έγκειται στο ότι οι άνθρωποι δεν ξεκινούν την σκέψη τους από το μηδέν κάθε δευτερόλεπτο καθώς οι επίμονες σκέψεις έχουν μια συνέχεια. Τα παραδοσιακά νευρωνικά δίκτυα δεν μπορούν να το κάνουν αυτό και ουσιαστικά μοιάζουν σαν ένα μεγάλο κενό. Τα επαναλαμβανόμενα νευρωνικά δίκτυα έχουν βρόγχους που τους επιτρέπουν να διατηρούν

την πληροφορία. Ουσιαστικά είναι δίκτυα όπου οι επαναληπτικές διαδικασίες (loops) που συμβαίνουν τους επιτρέπουν να έχουν αυτή την ιδιαιτερότητα τα διατήρησης μνήμης.



Εικόνα 12: Απεικόνιση αρχιτεκτονικής επαναλαμβανόμενου νευρωνικού δικτύου ([medium.com/explore\\_artificial\\_intelligence](https://medium.com/explore_artificial_intelligence))

Στην εικόνα 12 παρουσιάζεται ένα παράδειγμα αρχιτεκτονικής ενός τέτοιου δικτύου. Μια επαναληπτική διαδικασία (βρόγχος) επιτρέπει την ροή της πληροφορίας από το ένα επίπεδο στο άλλο. Ένα επαναληπτικό νευρωνικό δίκτυο μπορεί να θεωρηθεί ένα πολλαπλό αντίγραφο του παραπάνω δικτύου όπου το κάθε στρώμα θα διαβιβάζει μία πληροφορία στο επόμενο βήμα ακολουθώντας την επαναληπτική αυτή διαδικασία πρωτού μεταφερθεί.



Εικόνα 13: Απεικόνιση λειτουργίας ενός επαναλαμβανόμενου νευρωνικού δικτύου

Αυτή η μορφή αλυσίδας (Εικόνα 13) αποκαλύπτει την συσχέτιση των δικτύων αυτών με λίστες και αληλουχίες. Είναι ουσιαστικά η φυσική αρχιτεκτονική του RNN. Τα τελευταία χρόνια υπήρξε πάρα πολύ μεγάλη επιτυχία στην εφαρμογή επαναλαμβανόμενων νευρωνικών δικτύων σε διάφορων ειδών προβλήματα όπως αναγνώριση ομιλίας, μοντελοποίηση γλώσσας, μετάφραση, προβολή εικόνας κ.α.

### 3.5 Λειτουργία νευρωνικών δικτύων

Το νευρωνικό δίκτυο αποτελείται από δύο στάδια λειτουργίας. Στο πρώτο βρίσκεται η εκπαίδευση του νευρωνικού δικτύου δηλαδή, η διαδικασία κατά την οποία το δίκτυο κάνει εκμάθηση των δεδομένων (training set) όπου, ένα σύνολο από τιμές παρατηρήσεων



εισάγονται στην είσοδο του δικτύου και με το τέλος της εκπαίδευσης τους εξάγουν αποτελέσματα. Χρησιμοποιώντας το σετ εκμάθησης και τον κατάλληλο αλγόριθμο γίνεται εκπαίδευση του νευρωνικού δικτύου υπολογίζοντας τα βάρη και τις πολώσεις σε περίπτωση ύπαρξής τους. Ο σκοπός της διαδικασίας είναι να ελαχιστοποιηθεί το σφάλμα στην πρόβλεψη. Το δεύτερο στάδιο είναι η διαδικασία πρόβλεψης. Σε αυτό το σημείο δημιουργείται ένα σετ δεδομένων προς έλεγχο (test set). Για να υπολογιστούν οι τιμές στην έξοδο λαμβάνονται υπόψη από το νευρωνικό δίκτυο οι τιμές από τα βάρη (weights) και τις πιθανές πολώσεις (biases) τα οποία υπολογίστηκαν κατά την διαδικασία εκμάθησης. Τέλος, για να γίνει υπολογισμός του στατιστικού σφάλματος πρόβλεψης λαμβάνονται υπόψη οι προβλεπόμενες τιμές στην έξοδο συγκρινόμενες με τις επιθυμητές τιμές από το σετ ελέγχου.

Για να έχει το νευρωνικό δίκτυο την βέλτιστη απόδοση θα πρέπει να λάβουμε υπόψη τους εξής παράγοντες οι οποίοι έχουν μεγάλη σημασία στην σωστή λειτουργία του.

- Ο ορισμός της αρχιτεκτονικής του όπου λαμβάνεται υπόψη ο αριθμός των κρυμμένων στρωμάτων, ο αριθμός των νευρώνων που υπάρχει σε κάθε στρώμα, η συνάρτηση ενεργοποίησης, ο αλγόριθμος για την εκπαίδευση καθώς και αριθμός επαναλήψεων.
- Ο καθορισμός του ποσοστού, από τα σετ δεδομένων που έχουμε στην διάθεσή μας, που θα χρησιμοποιηθεί ως σετ εκπαίδευσης και ως σετ ελέγχου. Το σύνηθες είναι είτε 75% των δεδομένων να χρησιμοποιείται για εκπαίδευση και το 15% χρησιμοποιείται για έλεγχο, είτε το 80% για εκπαίδευση και το 20% για έλεγχο.
- Η ικανότητα του νευρωνικού δικτύου να προβλέψει με μικρό στατιστικό σφάλμα πρόβλεψης τόσο κατά την εκπαίδευση του όσο και κατά τον έλεγχο.

Η διαδικασία εκπαίδευσης του νευρωνικού δικτύου είναι επαναλαμβανόμενη και ως αποτέλεσμα αυτού είναι μια διαδικασία η οποία απαιτεί ένα μεγάλο εύρος χρόνου συγκεκριμένα, όταν υπάρχει μεγάλος όγκος δεδομένων ή όταν ο αριθμός των νευρώνων στα επίπεδα του δικτύου είναι μεγάλος. Ο αριθμός των νευρώνων στο κρυμμένο στρώμα ορίζεται μέσω της διαδικασίας δοκιμής σφάλματος (trial and error) καθώς δεν υπάρχει κάποια συγκεκριμένη διαδικασία από την οποία μπορούμε να αποφασίσουμε τον αριθμό των νευρώνων. Στην περίπτωση όπου στο κρυμμένο επίπεδο ο αριθμός των νευρώνων είναι μικρός το νευρωνικό δίκτυο δεν μπορεί να κάνει αποτελεσματική εκμάθηση λόγω της πολυπλοκότητας των σχέσεων. Εάν ο αριθμός των νευρώνων είναι πολύ μεγάλος τότε αντιμετωπίζουμε άλλου είδους προβλήματα όπως αυτό της υπέρπροσαρμογής (overfitting). Ο αριθμός των νευρώνων όπως μπορούμε να καταλάβουμε δεν είναι σταθερός αλλά αλλάζει σε κάθε διαφορετική περίπτωση προβλήματος αλλά εξαρτάται και από τον όγκο των δεδομένων.

### 3.6 Εκπαίδευση νευρωνικών δικτύων

Τα νευρωνικά δίκτυα έχουν την βασική και ιδιαίτερη ικανότητα να εκπαιδεύονται από την πληροφορία που εισάγεται και, μέσα από τις διαδικασίες που λαμβάνουν χώρα μεταξύ των στρωμάτων να δίνουν πολύ αξιόπιστα αποτελέσματα (S.J Kuartzis, et. al , 1994). Οι μέθοδοι μάθησης χωρίζονται σε 2 κατηγορίες την **εποπτευόμενη μάθηση** (supervised learning) και τη **μη εποπτευόμενη μάθηση** (unsupervised learning).

#### i) Εποπτευόμενη μάθηση (supervised learning)

Αυτό το είδος χρησιμοποιείται είτε κατά την παλινδρόμηση (*towardsscience.com*) ώστε για κάποια δεδομένα εισόδου να παράγουμε δεδομένα εξόδου. Οι πιο συνηθισμένοι αλγόριθμοι είναι η λογική παλινδρόμηση (logistic regression), naive bayes, support vector machines, τεχνητά νευρωνικά δίκτυα (artificial neural networks), και τα τυχαία δάση (random forests).

#### ii) Μη εποπτευόμενη μάθηση (unsupervised learning)

Η βασική λειτουργία αυτού του είδους εκμάθησης είναι η συσσωμάτωση (clustering) (*towardsscience.com*) και χρησιμοποιείται κατά κύριο λόγο στην αναγνώριση φωτογραφιών.

### 3.7 Έλεγχος ακρίβειας της πρόβλεψης του νευρωνικού δικτύου μέσω σφάλματος

Ο έλεγχος της ακρίβειας των εξαγόμενων προβλέψεων για ένα νευρωνικό δίκτυο γίνεται μέσω των στατιστικών σφαλμάτων. Σφάλμα ονομάζουμε την αβεβαιότητα η οποία υπάρχει στην μέτρηση ενός φυσικού μεγέθους:

τιμή  $\pm$  αβεβαιότητα

Η αβεβαιότητα ισχύει και στην περίπτωση της πρόβλεψης η οποία ουσιαστικά είναι μια μέτρηση. Υπάρχουν πολλά είδη σφαλμάτων παρακάτω παραθέτουμε τα πιο σημαντικά.

**A) Μέσο τετραγωνικό σφάλμα (Mean Squared Error ή MSE):** Στην στατιστική το μέσο τετραγωνικό σφάλμα ορίζεται ως η μέση τετραγωνική διαφορά μεταξύ τιμής μέτρησης και πραγματικής τιμής. Το μέσο τετραγωνικό σφάλμα είναι μια συνάρτηση κινδύνου και μαθηματικά ορίζεται ως:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (A_i - \hat{A}_i)^2$$

**Β) Σφάλμα ρίζας μέσου τετραγώνου (Root Mean Squared Error ή RMSE):** Είναι η ρίζα του μέσου τετραγωνικού σφάλματος και η μαθηματική του έκφραση είναι:

$$RMSE = \sqrt{MSE}$$

**Γ) Κανονικοποιημένο σφάλμα ρίζας τετραγώνου (Normalized Root Mean Squared Error ή NRMSE):** Αυτό το είδος σφάλματος είναι το κανονικοποιημένο RMSE και εκφράζεται συνήθως ως ποσοστό όπου χαμηλές τιμές υποδεικνύουν καλύτερη μέτρηση. Σε μικρά δείγματα είναι πιθανό να επηρεαστεί από το μέγεθος του δείγματος.

$$NRMSE = \frac{RMSE}{y_{max} - y_{min}}$$

**Δ) Μέσο απόλυτο σφάλμα (Mean Absolute Error ή MAE):** Στην στατιστική το MAE είναι το μέτρο της διαφοράς μεταξύ δύο τιμών.

$$MAE = |A_i - \hat{A}_i|$$

**Ε) Μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error ή MAPE):** Το μέσο απόλυτο ποσοστιαίο σφάλμα είναι το μέσο απόλυτο σφάλμα εκφρασμένο επί τις εκατό.

### 3.8 Εφαρμογές νευρωνικών δικτύων και πλεονεκτήματα

#### Εφαρμογές

Το μεγάλο ενδιαφέρον που έχει αναπτυχθεί τα τελευταία χρόνια γύρω από τα νευρωνικά δίκτυα και η εφαρμογή τους σε διάφορων ειδών προβλήματα τα καθιστούν ένα πολύ ενδιαφέρον εργαλείο (Velido A., et al. 1999). Η συνεχής ανάπτυξη των υπολογιστών και ως εκ τούτου οι αλγόριθμοι έχουν συμβάλει τα μέγιστα ώστε τα νευρωνικά δίκτυα να χρησιμοποιούνται στην επίλυση μεγάλων προβλημάτων είτε στην βιομηχανία είτε στις επιχειρήσεις είτε στις επιστήμες που απαιτούσαν πολύπλοκες τεχνικές επίλυσης (Widrow, Bernard, 1994). Τα νευρωνικά δίκτυα βρίσκουν εφαρμογή καθ' όλη τη διάρκεια ζωής τους σε πολλούς κλάδους όπως

- A) Αυτοκίνηση
- B) Τραπεζικές εφαρμογές
- Γ) Άμυνα χωρών
- Δ) Ηλεκτρονική

- E) Οικονομία
- Z) Βιομηχανία
- H) Ιατρική
- Θ) Γεωλογία
- I) Ρομποτική
- K) Χρηματιστήριο
- Λ) Μηχανές επεξεργασίας οπτικοακουστικών μέσων
- M) Μεταφορές
- N) Τηλεπικοινωνίες

Επειδή, πλέον αποτελούν ένα ισχυρότατο εργαλείο, όπως καταλαβαίνουμε από την εφαρμογή τους σε τόσους πολλούς κλάδους, χρηματικά ποσά μεγάλου όγκου επενδύονται για ανάπτυξη λογισμικού και υλικού.

### Πλεονεκτήματα

Η σταθερή δομή τους και η ικανότητά τους στην εκμάθηση τα καθιστούν ικανά απέναντι σε μεγάλο εύρος πολύπλοκων προβλημάτων. Η χρήση λοιπόν νευρωνικών δικτύων έχει προσφέρει τα εξής πλεονεκτήματα:

**A) Μη – γραμμικότητα:** Οι νευρώνες είναι μη γραμμικοί ως προς την λειτουργία τους.

**B) Προσαρμοστικότητα:** Προσαρμογή των βαρών τους στις αλλαγές του δυναμικού περιβάλλοντος τους. Οι προσαρμογές χωρίς εντατικό έλεγχο μπορούν να οδηγήσουν σε κακής ποιότητας εκμάθηση για αυτό το λόγο χρειάζεται πολύ προσοχή όσον αφορά την επάρκεια των τιμών που ορίζουμε στις παραμέτρους του νευρωνικού δικτύου (epochs, neurons).

**Γ) Υλοποίηση σε τεχνολογία:** Η παράλληλη φύση του δικτύου το κάνει υλοποιήσιμο σε διάφορων είδους τεχνολογίες έτσι ώστε το νευρωνικό δίκτυο να μπορεί να χρησιμοποιηθεί σε εφαρμογές πραγματικού χρόνου.

# 4 ΝΕΥΡΩΝΙΚΑ ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ


## 4.1 Νευρωνικά μοντέλα και πρόβλεψη

Το πρόβλημα της πρόβλεψης του ηλεκτρικού φορτίου είναι ένα πρόβλημα που τα τελευταία χρόνια απασχολεί την αγορά σε μεγάλο βαθμό. Η πρόβλεψη του ηλεκτρικού φορτίου και κατ' επέκταση του ηλεκτρικού ρεύματος συνδέεται στενά με άλλα σύγχρονα επιστημονικά και τεχνικά προβλήματα όπως ο προγραμματισμός των βέλτιστων μονάδων παραγωγής ηλεκτρικής ενέργειας, η κατανάλωση καυσίμου, η εκμετάλλευση των ενεργειακών πόρων, οι εκπομπές αερίων θερμοκηπίου, η προσομοίωση των συστημάτων ισχύος και η μοντελοποίηση της ζήτησης ηλεκτρικής ενέργειας. Επειδή είναι αλληλένδετα με άλλα προβλήματα και καθήκοντα είναι ένα ερευνητικό θέμα που στοχεύει σε πολλούς τομείς. Οι προβλέψεις τιμών σχετίζονται με τις συναλλαγές και τις συμπεριφορές της αγοράς ενέργειας όπου πολλοί συμμετέχοντες σε αυτή (επιχειρήσεις κοινής ωφέλειας, φορείς εκμετάλλευσης δικτύων, λιανοπωλητές κ.α.) ενδιαφέρονται για την λήψη βραχυπρόθεσμων προβλέψεων. Τα τελευταία χρόνια όπου η τεχνητή νοημοσύνη (Artificial Intelligence) κάνει μεγάλα άλματα προόδου μεγάλο ενδιαφέρον ο τομέας των τεχνητών νευρωνικών δικτύων (ANN). Παρακάτω παρουσιάζουμε μοντέλα τεχνητών νευρωνικών δικτύων που κάνουν πρόβλεψη του ηλεκτρικού φορτίου. Ένα αξιόπιστο νευρωνικό δίκτυο πρόβλεψης πρέπει να είναι εύκολο στην εφαρμογή και να χαρακτηρίζεται από υψηλό επίπεδο παραμετροποίησης (Panarakidis, Dragoumas, 2016). Τα μοντέλα δικτύων που χρησιμοποιούνται ευρέως για την πρόβλεψη του ηλεκτρικού φορτίου είναι τα εξής:

- A) Νευρωνικά Δίκτυα πρόσθιας κατεύθυνσης - ενός επιπέδου ή πολλαπλών επιπέδων (Feed Forward Neural Networks ή FFNNs)
- B) Δίκτυα λειτουργιών ακτινικής βάσης (radial basis function Networks ή RBFNs)
- Γ) Επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Networks ή RNN)
- Δ) Μηχανές υποστήριξης (Support Vector Mchines)
- E) Ασαφή Νευρωνικά Δίκτυα (Fuzzy Neural Networks)
- Z) Πιθανολογικά Νευρωνικά Δίκτυα (Propabilistic Neural Networks ή PNN)
- H) Υβριδικά νευρωνικά δίκτυα βραχυχρόνιου ορίζοντα
- Θ) Ιεραρχικά νευρωνικά δίκτυα βραχυχρόνιου ορίζοντα
- I) Τεχνητά νευρωνικά δίκτυα που συνδυάζουν όμοιες ημερήσιες προσεγγίσεις

### α) Νευρωνικά Δίκτυα πρόσθιας κατεύθυνσης (Feed Forward Neural Networks ή FFNNs)


Αυτού του είδους τα νευρωνικά δίκτυα λόγω του ότι θεωρούνται τα πιο απλά νευρωνικά δίκτυα βρίσκουν εφαρμογή από την αρχή της επιστήμης των νευρωνικών δικτύων. Μπορούν να εξάγουν προβλέψεις οι οποίες όμως σε χρονοσειρές οι οποίες εμφανίζουν πολυπλοκότητα δεν είναι μεγάλης ακρίβειας ειδικά όσον αφορά τις ακραίες μεταβολές. Οι Hippert, Pedreira, Souza, (Hibbert, 2001) εξετάζουν άρθρα στα οποία κατά κύριο λόγο χρησιμοποιήθηκαν αυτού του είδους τα νευρωνικά δίκτυα. Καταλήγουν στο συμπέρασμα ότι τα μοντέλα μπορούν να πρόβλέψουν ικανοποιητικά αν και δεν είναι πάντα πειστικά.



Εικόνα 14: Νευρωνικό Δίκτυο εμπρός τροφοδότησης δύο κρυμμένων επιπέδων (Hibbert, 2001).

### β) Δίκτυα ακτινικής βάσης (RBNs)

Τα δίκτυα ακτινικής βάσης (RBNs) είναι ένας άλλος τύπος FFNNs. Ένα RBN δίκτυο περιλαμβάνει ένα κρυφό στρώμα. Έχει το ρόλο της συνάρτησης ενεργοποίησης του κρυμμένου στρώματος (Ranaweera, 1995). Αυτός ο τύπος τεχνητού νευρωνικού δικτύου είναι σε θέση να προσομοιώνει σύνθετες σχέσεις στις οποίες βασίζονται τα δεδομένα και μπορεί και προσαρμόζεται γρήγορα στις πιθανές αλλαγές αυτών των σχέσεων. Άρα αυτά τα δίκτυα έχουν τρία επίπεδα, ένα στρώμα εισόδου, ένα κρυμμένο στρώμα με μη γραμμική λειτουργία ενεργοποίησης RBF (radial basis function) και ένα γραμμικό επίπεδο στρώματος εξόδου. Η είσοδος μπορεί να μοντελοποιηθεί σαν ένα διάνυσμα πραγματικών αριθμών. Η έξοδος είναι μια κλιμακωτή συνάρτηση του διανύσματος εισόδου. Η Ranaweera παρουσιάζει ένα νευρωνικό δίκτυο ακτινικής βάσης και ένα ένα νευρωνικό δίκτυο πίσω διάδοσης όπου εκ των αποτελεσμάτων αποδεικνύεται πως το νευρωνικό δίκτυο ακτινικής βάσης εξάγει ακτιβέστερα αποτελέσματα στην πρόβλεψη φορτίου σε σχέση με αυτό της πίσω διάδοσης.



Εικόνα 15 Απεικόνιση RBN νευρωνικού δικτύου ([en.wikipedia.org/Radial\\_basis\\_function\\_network](http://en.wikipedia.org/Radial_basis_function_network))

### γ) Μακροχρόνιας / Βραχυχρόνιας Μνήμης Νευρωνικά Δίκτυα ή Long Short Term Memory Neural Networks (LSTM)

Τα επαναλαμβανόμενα νευρωνικά δίκτυα μακροχρόνιας βραχυχρόνιας μνήμης είναι ένα είδος νευρωνικών δικτύων RNN τα οποία χρησιμοποιούνται στον τομέα της βαθιάς εκμάθησης (Deep Learning) για προβλέψεις τιμών χρονοσειρών όπως η χρονοσειρά του φορτίου (Kong, et. al 2017). Σε αντίθεση με τα απλά επαναλαμβανόμενα νευρωνικά δίκτυα το LSTM έχει συνδέσεις ανατροφοδότησης που το καθιστούν υπολογιστή γενικής χρήσης, υπό την έννοια ότι μπορεί να υπολογίσει μεγάλο εύρος προβλημάτων. Δεν μπορεί να επεξεργάζεται μόνο μονάδες δεδομένων όπως εικόνες αλλά και ολόκληρες ακολουθίες δεδομένων π.χ. ομιλία ή βίντεο. Μία LSTM μονάδα εντός νευρωνικού δικτύου αποτελείται από ένα κελί, μία πύλη εισόδου, μια πύλη εξόδου, και μία πύλη μνήμης. Το κελί θυμάται τιμές σε αυθαίρετα χρονικά διαστήματα και οι τρεις πύλες είναι ρυθμιστές της ροής πληροφορίας μέσα και έξω από το κελί. Τα δίκτυα LSTM είναι κατάλληλα για την ταξινόμηση, την επεξεργασία και την πραγματοποίηση προβλέψεων βάσει δεδομένων χρονοσειρών, καθώς μπορεί να υπάρξουν καθυστερήσεις άγνωστης διάρκειας μεταξύ σημαντικών γεγονότων σε μια χρονολογική σειρά. Έτσι είναι πιο αποτελεσματικά σε σχέση με τα απλά RNN νευρωνικά δίκτυα ή άλλου είδους μοντέλα όπως τα μοντέλα Markov. Οι Kong, Dong, Jia, Hill, Hu και Zhang (Kong, et. al 2017) αναπτύσσουν ένα νευρωνικό μοντέλο LSTM για την πρόβλεψη του ηλεκτρικού φορτίου όπου το LSTM μοντέλο εξάγει πολύ πιο ακριβείς προβλέψεις συγκρινόμενο με νευρωνικά δίκτυα πίσω διάδοσης.

### δ) Μηχανές υποστήριξης (Support Vector Machines ή SVM)

Τα SVM παρέχουν μια μη γραμμική χαρτογράφηση των αρχικών δεδομένων σε χώρο υψηλών διαστάσεων (Panarakidis, Dragoumas, 2016). Τα όρια του χώρου οριοθετούνται χρησιμοποιώντας γραμμική λειτουργία. Παρέχουν γενική λύση σε ένα πρόβλημα σε αντίθεση με τα MLPs που μπορούν να λειτουργούν εντός των τοπικών ελαχίστων. Αυτό το γεγονός έχει παρατηρηθεί πολλές φορές στις έρευνες για την πρόβλεψη του φορτίου. Το SVM χρησιμοποιείται για την εκτίμηση των διαστημάτων προβλέψεων που ποσοτικοποιούν την αβεβαιότητα που σχετίζεται με τις προβλέψεις εκτιμώντας τα όρια των ποσοτήτων που έχουν οριστεί ως στόχοι.

### ε) Ασαφή Νευρωνικά Δίκτυα (Fuzzy Neural Networks ή FNN)

Μια άλλη προσέγγιση στην πρόβλεψη των τιμών είναι η συνεργατική λειτουργία μεταξύ της ασαφούς λογικής (Fuzzy Logic ή FL) και των ANN. Υπάρχουν δύο κατηγορίες σύνδεσης των δύο αυτών λειτουργιών (Panarakidis, Dragoumas 2016). Χρησιμοποίηση των FL και των ANN στο ίδιο σύστημα δηλαδή νευροασαφή συστήματα όπως τα ANFIS και χρησιμοποίηση των δύο λειτουργιών ξεχωριστά σαν διαδικασίες πρόβλεψης όπου τα αποτελέσματα τους συνδυάζονται σε μια μετεγενέστερη λειτουργία. Στην τελευταία περίπτωση η πρόβλεψη επιτυγχάνεται μέσω μιας γλωσσικής περιγραφής των σχέσεων μεταξύ δεδομένων εισόδου. Από την άλλη πλευρά συνήθως στις υλοποιήσεις του ANFIS οι

εισροές στο δίκτυο αφορούν μόνο ιστορικές τιμές που πλησιάζουν τις ημέρες των τιμών που πρέπει να προβλεφθούν.

### ζ) Πιθανολογικά Νευρωνικά Δίκτυα (Propabilistic Neural Networks ή PNN)

Οι αιχμές στην χρονοσειρά του ηλεκτρικού φορτίου είναι τιμές οι οποίες μπορούν να προκαλέσουν σημαντικές οικονομικές επιπτώσεις στους συμμετέχοντες στην αγορά (Panarakidis, Dragoumas, 2016). Υπάρχουν μερικές έρευνες που έχουν επικεντρωθεί σε αυτό το πρόβλημα και προτίνουν διάφορες τεχνικές. Η πιο κοινή προσέγγιση είναι η εφαρμογή Πιθανολογικών Νευρωνικών Δικτύων (PNN). Τα PNN είναι ταχέως εκπαιδευόμενα δίκτυα προώθησης με μία μόνο έξοδο. Μέσω μιας προκαταρκτικής ανάλυσης, εξάγεται η κατώτατη τιμή που αναγνωρίζεται ως αιχμή. Το PNN χρησιμοποιείται για την πρόβλεψη δηλαδή αν είναι αιχμή ή όχι, ή σε συνδυασμό με ένα ANN μπορεί να προβλεφθεί και η τιμή της αιχμής.

### η) Υβριδικά νευρωνικά δίκτυα βραχυχρόνιου ορίζοντα

Στο άρθρο *A hybrid learning for neural networks applied to short term load forecasting* (Topalli, Erkmen, 2003) γίνεται πρόβλεψη του ηλεκτρικού φορτίου με την βοήθεια των υβριδικών νευρωνικών δικτύων. Το είδος αυτών των δικτύων έχουν βραχυχρόνιο ορίζοντα πρόβλεψης. Τα δεδομένα εισαγωγής είναι πραγματικά ιστορικά στοιχεία (ηλεκτρικό φορτίο) της τούρκικης εταιρίας ηλεκτρισμού. Είναι δίκτυα πολλών στρωμάτων νευρώνων τα οποία αποτελούνται από έναν ή περισσότερους βρόγχους ανατροφοδότησης.




Fig. 1. Recurrent MLP structure.

Εικόνα 16: Υβριδικό νευρωνικό δίκτυο βραχυχρόνιου ορίζοντα (Topalli, Erkmen, 2003)



Το μοντέλο της εικόνας 19 είναι μόνομεταβλητό όπου μεταβλητή το ηλεκτρικό φορτίο, η  $Y(n)$ , για την οποία γίνεται η πρόβλεψη μιας έξοδου. Το μέσο σφάλμα των δικτύων είναι κοντά στο 2.31% όπου μπορούμε να καταλάβουμε την επιτυχία του μοντέλου. Τα υβριδικά μοντέλα δίνουν γενικά καλύτερες προβλέψεις σε βραχυχρόνιο ορίζοντα.. Έχουνε το πλεονέκτημα της γρήγορης προσαρμογής σε καταστάσεις πραγματικού χρόνου και δεν είναι ευαίσθητα σε απότομες αλλαγές του περιβάλλοντος όπως επίσης και ότι τα σφάλματα τους είναι μικρότερα σε σχέση με τα απλά όπου δεν γίνεται κάποιου είδους ομαδοποίηση των δεδομένων.

θ) Ιεραρχικά νευρωνικά δίκτυα βραχυχρόνιου ορίζοντα

Στο άρθρο *A hierarchical neural model in short-term load forecasting (Otavio A.S., et. al, 2004)* διακρίνουμε ένα ιεραρχικό νευρωνικό δίκτυο το οποίο χρησιμοποιείται στην πρόβλεψη του ηλεκτρικού φορτίου για κοντινό χρονικό ορίζοντα. Το μοντέλο αποτελείται από δύο SOM (self organizing map) δίκτυα. Η συγκεκριμένη δομή του δικτύου του δίνει την δυνατότητα να αποδοτικής λειτουργίας με τα δεδομένα εισόδου. Έχει καλή μνήμη όσον αφορά τα ιστορικά δεδομένα και ως αποτέλεσμα παράγει ικανοποιητικές προβλέψεις καθώς κωδικοποιεί και χειραγωγεί την πληροφορία αποτελεσματικά. Έχει καλύτερη απόδοση σε βραχυχρόνιο ορίζοντα. Το μοντέλο απαρτίζεται από εφτά εισόδους στις οποίες εισάγονται τα φορτία του παρελθόντος. Στην πρώτη το τρέχον φορτίο, στην δεύτερη αυτό της προηγούμενης ώρας, στην τρίτη το φορτίο πριν 24 ώρες, στην τέταρτη το φορτίο πριν μια εβδομάδα, στην πέμπτη το φορτίο πριν μια εβδομάδα και 24 ώρες ενώ στις εισόδους έξι και επτά έχουμε ένα είδος κωδικοποίησης για την ώρα πρόβλεψης. Το μοντέλο αποτελείται από μία έξοδο. Η εκπαίδευση του μοντέλου γίνεται με συνηθισμένες τιμές (συγκεκριμένου εύρους) σε κανονικές συνθήκες. Το μοντέλο δίνει μικρό σφάλμα συγκρινόμενο με αυτό του MLP σε στατιστικά σφάλματα MAPE και MSE.




Fig. 1. HNM.

Εικόνα 17: Ιεραρχικό νευρωνικό δίκτυο (Otavio, et. al, 2004)

#### ι) Τεχνητά νευρωνικά δίκτυα που συνδυάζουν όμοιες ημερήσιες προσεγγίσεις

Στο άρθρο (Mandal, et. al, 2006) μπορούμε να δούμε μια μεθοδολογία για την πρόβλεψη του φορτίου σε βραχυχρόνιο ορίζοντα με τεχνητά νευρωνικά δίκτυα συνδυάζοντας όμοιες ημερήσιες τιμές. Χρησιμοποιούνται όμοια ημερήσια στοιχεία μεταξύ τους ώστε τα νευρωνικά δίκτυα να μάθουν την τάση των όμοιων τιμών. Γίνεται αξιολόγηση ομοιότητας μεταξύ της ημέρας πρόβλεψης και των προηγούμενων ημερών. Η καμπύλη πρόβλεψης του φορτίου χρησιμοποιεί στοιχεία από μέρες με ίδιες καιρικές συνθήκες με την ημέρα πρόβλεψης. Η ακρίβεια ενισχύεται προσθέτοντας τον παράγοντα της θερμοκρασίας. Το σφάλμα σε ένα βραχυχρόνιο ορίζοντα είναι μεταξύ 1% και 2.4%. Αυτό δείχνει ότι η μέθοδος δίνει αξιόπιστες προβλέψεις.





Fig. 2. Proposed neural network structure.

Εικόνα 18: Τεχνητό νευρωνικό δίκτυο που συνδυάζει όμοιες ημερήσιες προσεγγίσεις (Mandal, et. al, 2006)

## 4.2 Η Μέθοδος της βαθιάς εκμάθησης (Deep Learning ή DL)

Οι Lago, De Ridder και De Schutter (Lago, et. al, 2018) προτείνουν τέσσερα διαφορετικά μοντέλα βαθιάς εκμάθησης (Deep Learning) για την πρόβλεψη τιμών ηλεκτρικής ενέργειας και παρουσιάζονται οι βελτιώσεις στην ακρίβεια πρόβλεψης. Γίνεται σύγκριση και ανάλυση 27 κοινών προσεγγίσεων για την πρόβλεψη της ηλεκτρικής ενέργειας και αποδεικνύεται ότι τα μοντέλα βαθιάς εκμάθησης ξεπερνούν τις τελευταίες τεχνολογίες και επιτυγχάνουν στατιστικώς σημαντικά αποτελέσματα. Η ανάπτυξη των τελευταίων ετών στον τομέα των νευρωνικών δικτύων έχει οδηγήσει στην βαθιά εκμάθηση (DL). Ένα τέτοιου είδους δίκτυο δεν έχει απλώς ένα κρυφό στρώμα. Η επιτυχία των μοντέλων DL ξεκίνησε με εφαρμογές σε υπολογιστές και τα τελευταία χρόνια τα μοντέλα αυτά έχουν εξαπλωθεί σε εφαρμογές που σχετίζονται με την ενέργεια όπως ο τομέας της αιολικής ενέργειας (Marino, 2016). Η χρήση τέτοιων μοντέλων σε προβλέψεις μπορεί να βελτιώσει την ακρίβεια μέχρι και 30%. Προτείνεται η στρατηγική DL και για την ακριβή πρόβλεψη χρονοσειρών και συγκεκριμένα για επιτυχή πρόβλεψη ηλεκτρικής ενέργειας. Ουσιαστικά τα βασικά μοντέλα DNN (deep learning neural networks) είναι η φυσική προέκταση των MLPs με συναρτήσεις ενεργοποίησης διαφορετικές της σιγμοειδούς. Περισσότερο πολύπλοκα είναι τα RNN ένας τύπος νευρωνικού δικτύου που δημιουργεί επιπλέον

αντιστοιχίσεις για την συγκράτηση πληροφοριών (μνήμη) από προηγούμενες εισόδους και που είναι κατάλληλες για μοντελοποίηση δεδομένων. Τα δύο επαναστατικά δίκτυα τελευταίας τεχνολογίας είναι τα LSTM τα GRU. Ένας διαφορετικός τύπος δομής βαθιάς εκμάθησης είναι τα CNN.



Εικόνα 19: Νευρωνικό δίκτυο βαθιάς εκμάθησης (Deep Learning) (Lago, et. al, 2018)

# 5 ΥΠΟΛΟΓΙΣΤΙΚΗ ΕΦΑΡΜΟΓΗ

## 5.1 Εισαγωγή

Τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν για μοντελοποίηση καθώς και για την πρόβλεψη της χρονοσειράς του φορτίου είναι:

A) Νευρωνικό δίκτυο πρόσθιας τροφοδότησης (Feed Forward)

B) Επαναληπτικά δίκτυα πραγματικού χρόνου (Recurrent Neural Networks) και συγκεκριμένα Βραχυπρόθεσμης/Μακροπρόθεσμης μνήμης νευρωνικά δίκτυα ή LSTM

Γ) Νευρωνικά δίκτυα βαθιάς εκμάθησης LSTM

Τα μοντέλα χρησιμοποιούν ως εισόδους ιστορικά δεδομένα φορτίου σε ημερήσια κλίμακα για την περίοδο 1/1/14 ως 22/6/18 στην Ελλάδα, δηλαδή περίπου τεσσεράμισι έτη. Στόχος είναι η εκπαίδευση του μοντέλου δηλαδή η εύρεση των βαρών ώστε να υπάρξει ελαχιστοποίηση του σφάλματος πρόβλεψης. Ως δεδομένα εκμάθησης (training set) χρησιμοποιείται το 80% των ιστορικών δεδομένων ενώ το υπόλοιπο 20% χρησιμεύει στην δοκιμή του μοντέλου για πρόβλεψη τιμών. Ακολουθούμε αυτό το διαχωρισμό για μεταξύ των δεδομένων καθώς είναι ο πιο συνηθισμένος κατά την εκμάθηση των νευρωνικών δικτύων. Τέλος, κάνουμε πρόβλεψη υπολογίζοντας το μέσο τετραγωνικό σφάλμα για κάθε ένα από τα προαναφερθέντα μοντέλα νευρωνικών δικτύων σε διάφορους χρονικούς ορίζοντες. Εξάγονται και παραθέτονται τα σφάλματα πρόβλεψης καθώς και τα σφάλματα για την διαδικασία της εκμάθησης.

Η γλώσσα προγραμματισμού στην οποία αναπτύξαμε το νευρωνικό δίκτυο είναι η Python. Έγινε επιλογή της συγκεκριμένης γλώσσας διότι αναφέρεται στην βιβλιογραφία ως η καταλληλότερη έναντι άλλων (*Manilla & de Raadt, 2006*) είναι απλή, εύκολο το να εξοικειωθεί κάποιος με αυτή, είναι ελεύθερο λογισμικό με συνεχείς ανανεώσεις, όπως και μια υψηλού επιπέδου γλώσσα η οποία είναι περισσότερο ευέλικτη σε τέτοιου είδους προβλήματα τα οποία απαιτούν στενή παρακολούθηση των παραμέτρων. Επίσης, είναι η πιο διαδεδομένη γλώσσα προγραμματισμού για μηχανική εκμάθηση καθώς περιλαμβάνει βιβλιοθήκες και πακέτα όπως τα pandas, numpy, tensorflow, keras, sci kit learn τα οποία βοηθούν τα μέγιστα στην κατασκευή ενός νευρωνικού δικτύου όπως και ότι είναι αντικειμενοστραφής δηλαδή υποστηρίζει τον συναρτησιακό προγραμματισμό.

## 5.2 Δεδομένα

Τα δεδομένα που χρησιμοποιήσαμε τα πήραμε από την ιστοσελίδα του Ανεξάρτητου Διαχειριστή Μεταφοράς Ηλεκτρικής Ενέργειας (ΑΔΜΗΕ) όσον αφορά τα δεδομένα κατανάλωσης του ηλεκτρικού φορτίου ενώ τα μετεωρολογικά δεδομένα (θερμοκρασία,

βροχή, μέγιστη ταχύτητα και μέγιστη απόσταση ανέμου) από την ιστοσελίδα του μετεωρολογικού σταθμού Αχαρνών όπου προσφέρονται ελεύθερα. Δεδομένα από την Εθνική Μετεωρολογική Υπηρεσία (EMY) θα ήταν σαφώς πιο ποιοτικά και ακριβή καθώς είναι δεδομένα υψηλής ακρίβειας αλλά όχι ελεύθερα. Στο τέλος της εργασίας ακολουθεί παράρτημα στο οποίο παρουσιάζονται όλα τα δεδομένα τα οποία χρησιμοποιήθηκαν για την πρόβλεψη της καταναλώσης ηλεκτρικού φορτίου στην Ελλάδα.

### 5.3 Νευρωνικό δίκτυο πρόσθιας τροφοδότησης ενός επιπέδου – Μονομεταβλητό (Feed Forward Neural Network)

Ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης είναι ένα τεχνητό νευρωνικό δίκτυο όπου οι συνδέσεις μεταξύ των κόμβων δεν σχηματίζουν κάποιον κύκλο. Είναι δηλαδή διαφορετικό από τα επαναληπτικά νευρωνικά δίκτυα (Recurrent) καθώς δεν έχει μνήμη και είναι η πιο απλή μορφή νευρωνικού δικτύου. Είναι ο πρώτος και απλούστερος τύπος νευρωνικού δικτύου που επινοήθηκε. Σε αυτό το δίκτυο οι πληροφορίες, δηλαδή τα δεδομένα, μετακινούνται προς μια μόνο κατεύθυνση, προς τα εμπρός, από τους κόμβους εισόδου, μέσω των κρυφών κόμβων (hidden layers) στους κόμβους εξόδου.

Κατ' αρχάς εισάγουμε στο περιβάλλον της python τις κατάλληλες βιβλιοθήκες και τα πακέτα (pandas, numpy, tensorflow, keras, sci kit learn) που είναι απαραίτητα ώστε να μπορέσουμε να κατασκευάσουμε το μοντέλο νευρωνικού δικτύου. Στην Εικόνα 20 παρουσιάζονται οι εντολές εισαγωγής των βιβλιοθηκών και των πακέτων.

```
import pandas as pd
import numpy as np
import tensorflow as tf
%matplotlib inline
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import r2_score
from keras.models import Sequential
from keras.layers import Dense
from keras.callbacks import EarlyStopping
from keras.optimizers import Adam
from keras.layers import LSTM
```

Εικόνα 20: Εισαγωγή κατάλληλων βιβλιοθηκών και πακέτων για την κατασκευή του νευρωνικού μοντέλου

Στην Εικόνα 21 εισάγουμε τα δεδομένα μας στο περιβάλλον και αποτυπώνουμε ένα δείγμα αυτών.

```
df = pd.read_csv("DATATABLE2.csv")

print(df.head())
```

	RecDate	Average Daily Load	AVER TEMP(Celsius)	Rain(mm)	max Uw (Km/h)	\
0	1/1/2014	5415.13	7.5	6.9	9.3	
1	1/2/2014	5696.13	9.5	0.3	8.5	
2	1/3/2014	5787.54	9.1	0.0	4.9	
3	1/4/2014	5661.46	8.6	0.0	9.5	
4	1/5/2014	5496.54	9.5	0.0	7.2	

	Wind distance (km)
0	53.4
1	58.6
2	43.5
3	64.9
4	65.2

Εικόνα 21: Εισαγωγή δεδομένων και αποτίμηση δείγματος αυτού

Σε αυτό το είδος μοντέλου θα κρατήσουμε σαν μεταβλητή εισόδου μόνο το ημερήσιο φορτίο και θα προβλέψουμε βάση αυτού δηλαδή, δημιουργούμε ένα μονομεταβλητό νευρωνικό δίκτυο πρόσθιας τροφοδότησης (Feed Forward) (Εικόνα 22).


```
df.drop(['AVER TEMP(Celsius)', 'Rain(mm)', 'max Uw (Km/h)', 'Wind distance (km)'], axis=1, inplace=True)
df.info()
df['RecDate'] = pd.to_datetime(df['RecDate'])
df = df.set_index(['RecDate'], drop=True)
df.head(10)
```

RecDate	Average Daily Load
2014-01-01	5415.13
2014-01-02	5696.13
2014-01-03	5787.54
2014-01-04	5661.46
2014-01-05	5496.54
2014-01-06	5580.13
2014-01-07	5883.25
2014-01-08	5696.33
2014-01-09	5673.92
2014-01-10	5739.33

Εικόνα 22: Κρατάμε σαν μεταβλητή μόνο το ημερήσιο φορτίο για την δημιουργία μονομεταβλητού νευρωνικού δικτύου

Στην Εικόνα 23 κατασκευάζουμε το διάγραμμα της χρονοσειράς των ημερήσιων δεδομένων του φορτίου και γίνεται διαχωρισμός αυτών σε δεδομένα εκμάθησης (training data) και δεδομένα δοκιμής (test data) όπου ο διαχωρισμός παρουσιάζεται στην Εικόνα 24. Η δομή μετά τον διαχωρισμό των ιστορικών δεδομένων είναι 1462 τιμές ημερήσιου φορτίου ως δεδομένα εκμάθησης και 173 τιμές ως δεδομένα δοκιμής σύμφωνα με το ότι τα δεδομένα χωρίζονται 80% για εκμάθηση και 20% για δοκιμή (ή 75% εκμάθηση και 15% δοκιμή) ως βέλτιστη επιλογή συνήθως στις διαδικασίες εκμάθησης νευρωνικών δικτύων.

```
plt.figure(figsize=(10, 6))
df['Average Daily Load'].plot();
```




Εικόνα 23: Γραφική παράσταση χρονοσειράς ημερησίων τιμών φορτίου

```
split_date = pd.Timestamp('2018-01-01')
```

```
train = df.loc[:split_date]
test = df.loc[split_date:]
plt.figure(figsize=(10, 6))
ax = train.plot()
test.plot(ax=ax)
plt.legend(['train', 'test']);
```

<Figure size 720x432 with 0 Axes>



Εικόνα 24: Διαχωρισμός δεδομένων σε δεδομένα εκμάθησης και δεδομένα δοκιμής

Γίνεται «εξομάλυνση» των δεδομένων, δηλαδή κανονικοποίηση αυτών μεταξύ του διαστήματος  $[0, 1]$ , με την χρήση της συνάρτησης `MinMaxScaler` της βιβλιοθήκης `sci kit learn` ώστε τα δεδομένα εισόδου να είναι σε ένα συγκρίσιμο εύρος κάτι το οποίο είναι πολύ σημαντικό για πολλά δεδομένα εισόδων, και διαχωρίζουμε τα δεδομένα εκμάθησης σε εισόδους και εξόδους με ακολουθία π ρόσθιας τροφοδότησης. Όταν λ έμε ότι κανονικοποιούμε τα δεδομένα σε ένα διάστημα με την χρησιμοποίηση της συγκεκριμένης συνάρτησης εννοούμε ότι από έ να σετ δεδομένων παίρνουμε την μικρότερη και την μεγαλύτερη τιμή και χρησιμοποιώντας το τύπο  $z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}$  παίρνουμε τα κανονικοποιημένα δεδομένα. Τιμές σε χρόνο  $t-1$  χρησιμοποιούνται για να παράξουμε τιμές σε χρόνο  $t$ . Επίσης παίρνουμε ένα δείγμα της μορφής των κανονικοποιημένων δεδομένων (Εικόνα 25).

```

scaler = MinMaxScaler(feature_range=(0, 1))
train_sc = scaler.fit_transform(train.reshape(-1, 1))
test_sc = scaler.transform(test.reshape(-1, 1))

X_train = train_sc[:-1]
y_train = train_sc[1:]

X_test = test_sc[:-1]
y_test = test_sc[1:]

print(X_train[:10])

[[0.4776617 ]
 [0.54340731]
 [0.56479452]
 [0.53529556]
 [0.49670921]
 [0.51626677]
 [0.5871878 ]
 [0.5434541 ]
 [0.53821083]
 [0.55351482]]

```

Εικόνα 25: Κανονικοποίηση των ιστορικών δεδομένων φορτίου και δημιουργία εισόδων εξόδων για το νευρωνικό δίκτυο. Κατασκευάζουμε το μονομεταβλητό νευρωνικό δίκτυο μιας εισόδου, ενός «κρυμμένου» στρώματος, και μιας εξόδου. Το «κρυμμένο» στρώμα αποτελείται από 20 νευρώνες (units). Το δίκτυο εκπαιδεύει τα ιστορικά δεδομένα για 100 εποχές (επαναλήψεις) και ως συνάρτηση ενεργοποίησης χρησιμοποιούμε την γραμμική συνάρτηση Rectifier (Relu) (Εικόνα 26).

```

nn_model = Sequential()
nn_model.add(Dense(20, input_dim=1, activation='relu'))
nn_model.add(Dense(1))
nn_model.compile(loss='mean_squared_error', optimizer='adam')
early_stop = EarlyStopping(monitor='loss', patience=2, verbose=1)
history = nn_model.fit(X_train, y_train, epochs=100, batch_size=100, verbose=1, callbacks=[early_stop], shuffle=False)

```

```

Epoch 1/100
1461/1461 [-----] - 1s 844us/step - loss: 0.2353
Epoch 2/100
1461/1461 [-----] - 0s 96us/step - loss: 0.1632
Epoch 3/100
1461/1461 [-----] - 0s 81us/step - loss: 0.1115
Epoch 4/100

```

Εικόνα 26: Κατασκευή μονομεταβλητού Νευρωνικών δίκτυου Feed Forward

Μετά την εκμάθηση του δικτύου εξάγεται το σφάλμα εκμάθησης για κάθε μία “εποχή” (επανάληψη εισόδου των δεδομένων) το οποίο μειώνεται σε κάθε επανάληψη. Το μέσο τετραγωνικό σφάλμα για την εκμάθηση ξεκινώντας από το 20% περίπου στο τέλος της εκμάθησης μειώνεται στο 0.6 % . Στη συνέχεια χρησιμοποιώντας την συνάρτηση `predict()` της βιβλιοθήκης Keras εξάγουμε τις προβλέψεις για τα δεδομένα δοκιμής και υπολογίζουμε τον συντελεστή προσδιορισμού γνωστό ως  $R^2$  ή R Squared. Ο συντελεστής προσδιορισμού έχει την τιμή 0.783 (Εικόνα 27) για τα δεδομένα εκμάθησης (Training Set) και 0.736 για τα δεδομένα δοκιμής (Test Set) τα οποία είναι άνω του μετρίου για το διάστημα [0,1] στο οποίο ορίζεται ο συντελεστής  $R^2$  ο οποίος μετρά το ποσοστό διακύμανσης του σετ δοκιμής. Για τιμή 0 δεν έχουμε εφαρμογή των σετ δοκιμής στο σετ εκμάθησης ενώ για τιμή 1 έχουμε τέλεια εφαρμογή. Υπολογίζουμε το μέσο τετραγωνικό σφάλμα μεταξύ των προβλεπόμενων και των πραγματικών τιμών, για τα δεδομένα δοκιμής, και κατασκευάζουμε την γραφική παράσταση αυτών (Εικόνα 28).



```


y_pred_test_nn = nn_model.predict(X_test)
y_train_pred_nn = nn_model.predict(X_train)

print(y_pred_test_nn)
print(y_train_pred_nn)

print("The R2 score on the Train set is:\t{:0.3f}".format(r2_score(y_train, y_train_pred_nn)))
print("The R2 score on the Test set is:\t{:0.3f}".format(r2_score(y_test, y_pred_test_nn)))

```

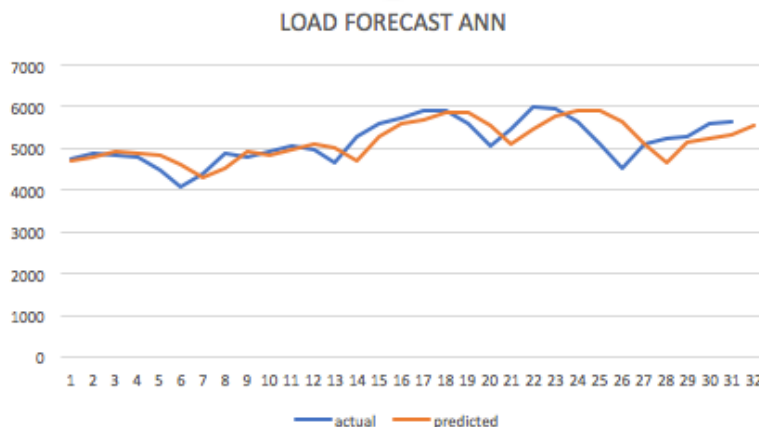
Εικόνα 27: Πρόβλεψη τιμών για τα δεδομένα δοκιμής και αποτύπωση του συντελεστή προσδιορισμού



Εικόνα 28: Γραφική παράσταση των τιμών πρόβλεψης και των πραγματικών τιμών του σετ δοκιμής 173 τιμών.

Το κανονικοποιημένο μέσο τετραγωνικό σφάλμα για τις προβλέψεις των δεδομένων δοκιμής είναι 1.98 % και ο συντελεστής προσδιορισμού  $R^2$  για το σετ εκμάθησης είναι 0.784 ενώ για το σετ δοκιμής είναι 0.740. Από τα στατιστικά σφάλματα και τον συντελεστή προσδιορισμού καταλαβαίνουμε ότι στο νευρωνικό δίκτυο ANN έχει γίνει σωστή εκπαίδευση των δεδομένων.

Μετά την διαδικασία εκμάθησης βάζουμε το μοντέλο να προβλέψει τις επόμενες 32 μέρες παρουσιάζουμε την γραφική παράσταση και εξάγουμε τα κανονικοποιημένο μέσο τετραγωνικό σφάλμα πρόβλεψης (NRMSE).



Εικόνα 29: Γραφική παράσταση προβλεπόμενων και πραγματικών τιμών φορτίου για ορίζοντα 1 μήνα.

Το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NRMSE) μεταξύ προβλεπόμενων και πραγματικών τιμών για πρόβλεψη με το μοντέλο νευρωνικού δικτύου ANN πρόσθιας

εκμάθησης (FNN) ανέρχεται στο 11%. Παρατηρώντας την Εικόνα 29 παρατηρούμε ότι το μοντέλο μπορεί να προβλέψει την τάση των πραγματικών τιμών σε κάποια σημεία την χρονοσειράς αλλά υστερεί στα χρονικά διαστήματα όπου εμφανίζονται μεγάλες μεταβολές για τις τιμές του ηλεκτρικού φορτίου. Αυτό είναι λογικό καθώς η κατεύθυνση της πληροφορίας εντός του νευρωνικού δικτύου εμπρός τροφοδότησης είναι μόνο προς τα μπροστά οπότε αυτό του είδους το νευρωνικό δίκτυο δεν έχει τους μηχανισμούς ώστε να γίνει σωστή εκμάθηση σε παρελθούσες μεταβολές των ιστορικών δεδομένων ώστε να είναι ικανό να προβλέψει με ακρίβεια νέες μεταβολές σε μελλοντικό χρόνο.

## 5.4 Επαναληπτικό Νευρωνικό δίκτυο μακροχρόνιας/βραχυχρόνιας μνήμης ενός επιπέδου - Πολυμεταβλητό (Recurrent Neural Network – Long Short Term Memory)

Τα νευρωνικά δίκτυα μακροχρόνιας/βραχυχρόνιας μνήμης είναι μία αρχιτεκτονική τεχνητών και επαναλαμβανόμενων νευρωνικών δικτύων (RNN) που χρησιμοποιείται στον τομέα της εκμάθησης Deep Learning. Σε αντίθεση με τα απλά ανεστραμμένα νευρωνικά δίκτυα, τα LSTM έχουν συνδέσεις ανατροφοδότησης που το καθιστούν πιο πολύπλοκο σαν δίκτυο αλλά και πιο αποδοτικό στους υπολογισμούς και στις προβλέψεις δεδομένων. Τέτοιου είδους νευρωνικά δίκτυα έχουν το πλεονέκτημα της μνήμης.

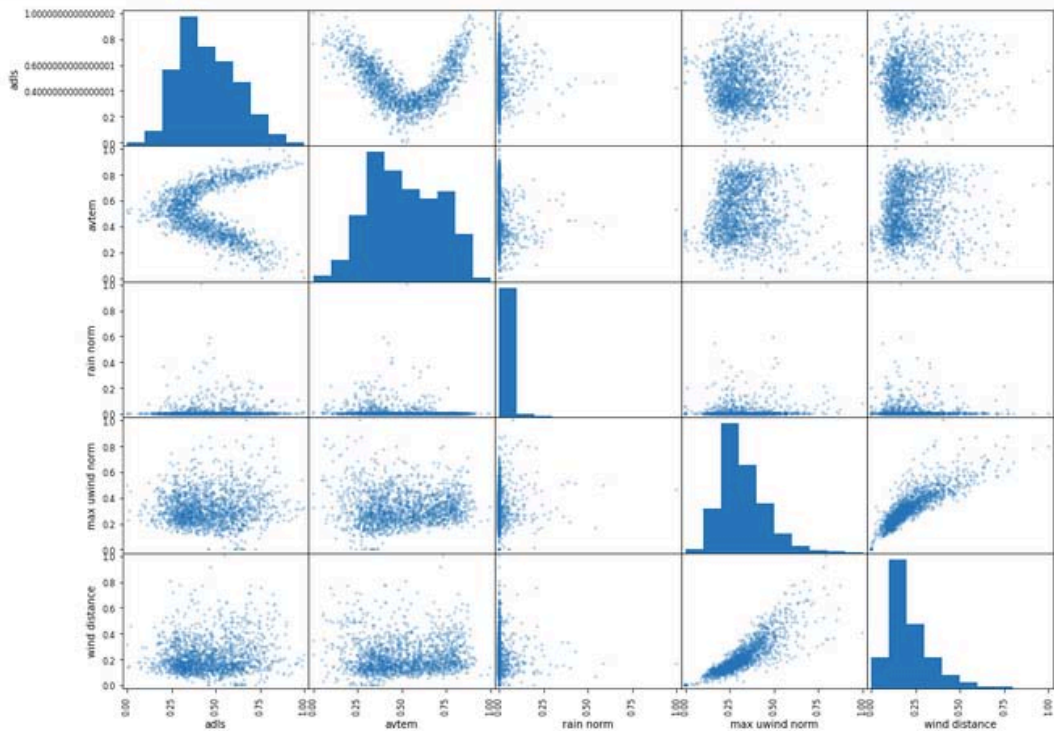
Ακολουθώντας τα ίδια βήματα με το προηγούμενο μοντέλο (εισαγωγή βιβλιοθηκών και σεν δεδομένων) κατασκευάζουμε μοντέλο νευρωνικού δικτύου LSTM πολυμεταβλητό. Μεταβλητές είναι η τιμή του φορτίου, η θερμοκρασία, το πάχος της βροχής, η μέγιστη ταχύτητα του αέρα, καθώς και η απόσταση του αέρα από τον σταθμό μετεωρολογικών δεδομένων. Κατασκευάζουμε τον πίνακα συσχέτισης (Εικόνα 30) και τα διαγράμματα διασποράς (Εικόνα 31) μεταξύ των μεταβλητών ώστε να ελέγξουμε την συσχέτιση μεταξύ των μεταβλητών του σεν δεδομένων.

df.corr()					
	adls	avtem	rain norm	max uwind norm	wind distance
adls	1.000000	-0.094138	0.080744	0.073149	0.107568
avtem	-0.094138	1.000000	-0.128302	0.048312	0.045002
rain norm	0.080744	-0.128302	1.000000	0.078570	-0.014287
max uwind norm	0.073149	0.048312	0.078570	1.000000	0.846872
wind distance	0.107568	0.045002	-0.014287	0.846872	1.000000

Εικόνα 30: Πίνακας συσχέτισης μεταξύ των μεταβλητών του σεν δεδομένων

Η ιδέα να χρησιμοποιήσουμε ένα πολυμεταβλητό μοντέλο νευρωνικού δικτύου LSTM πηγάζει από το γεγονός ότι, μεταβλητές οι οποίες μεταξύ τους έχουν συσχέτιση, δηλαδή η μια επηρεάζει την άλλη, έχουν πληροφορία η οποία μπορεί να φανεί αρκετά χρήσιμη στην ανάπτυξη ενός νευρωνικού μοντέλου το οποίο μπορεί να εκμεταλευτεί τέτοιες

αλληλεξαρτήσεις μεταξύ των μεταβλητών εισόδου για να παράγει πιο αξιόπιστες και πιο σταθερές προβλέψεις.



Εικόνα 31: Διαγράμματα διασποράς για τις μεταβλητές του σετ δεδομένων

Από τον πίνακα συσχέτισης και τα διαγράμματα διασποράς παρατηρούμε ότι η τιμή του φορτίου συσχετίζεται μόνο με την θερμοκρασία, μη γραμμικά καθώς μπορούμε να διακρίνουμε ένα παραβολικό σχηματισμό στο διάγραμμα διασποράς, με όλες τις άλλες μεταβλητές δεν υπάρχει σημαντική συσχέτιση

Αναπτύσσουμε το πολυμεταβλητό μοντέλο νευρωνικού δικτύου LSTM με ένα κρυμμένο στρώμα (hidden layer) και μονομεταβλητή εξόδο (φορτίο). Αρχικά κάνουμε εισαγωγή των βιβλιοθηκών στο περιβάλλον rython (Εικόνα 32), δημιουργούμε την ακολουθία εισόδων εξόδων με την οποία το νευρωνικό δίκτυο θα πραγματοποιήσει την εκμάθηση (Εικόνα 33). Στην περίπτωση μας επιλέξαμε να παίρνει σαν είσοδο την τιμή για χρόνο  $t - 1$  για να προβλέψει την τιμή σε χρόνο  $t$ . Κάνουμε εισαγωγή του σετ δεδομένων στο περιβάλλον και κατασκευάζουμε την γραφική παράσταση για το φορτίο, τη θερμοκρασία, τη βροχή, την μέγιστη ταχύτητα του ανέμου.

```

import numpy as np
import keras as kr
import tensorflow as tf
from math import sqrt
from numpy import concatenate
from matplotlib import pyplot
from pandas import read_csv
from pandas import DataFrame
from pandas import concat
import pandas as pd
from sklearn.preprocessing import MinMaxScaler
from sklearn.preprocessing import LabelEncoder
from sklearn.metrics import mean_squared_error
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM

```

Εικόνα 32: Εισαγωγή βιβλιοθηκών στο περιβάλλον python

```

def series_to_supervised(data, n_in=1, n_out=1, dropnan=True):
    n_vars = 1 if type(data) is list else data.shape[1]
    df = DataFrame(data)
    cols, names = list(), list()
    # input sequence (t-n, ... t-1)
    for i in range(n_in, 0, -1):
        cols.append(df.shift(i))
        names += [('var%d(t-%d)' % (j+1, i)) for j in range(n_vars)]
    # forecast sequence (t, t+1, ... t+n)
    for i in range(0, n_out):
        cols.append(df.shift(-i))
        if i == 0:
            names += [('var%d(t)' % (j+1)) for j in range(n_vars)]
        else:
            names += [('var%d(t+%d)' % (j+1, i)) for j in range(n_vars)]
    # put it all together
    agg = concat(cols, axis=1)
    agg.columns = names
    # drop rows with NaN values
    if dropnan:
        agg.dropna(inplace=True)
    return agg

```

Εικόνα 33: Κατασκευή ακολουθίας εισόδου εξόδου

Στην Εικόνα 33 κατασκευάζουμε την ακολουθία με την οποία το νευρωνικό μοντέλο θα παίρνει εισόδους και θα εξάγει εξόδους. Σε αυτή την ακολουθία που κατασκευάσαμε για αυτό το είδος μοντέλου το ευρωνικό δίκτυο παίρνει εισόδους για  $t-1$  και εξάγει εξόδους για  $t$ .

```

dataset = pd.read_csv("DATATABLE.csv", header=0, index_col=0)
#print(dataset.describe())
print(dataset.head())
values = dataset.values

# specify columns to plot
groups = [0, 1, 2, 3, 4]
i = 1
# plot each column
pyplot.figure()
for group in groups:
    pyplot.subplot(len(groups), 1, i)
    pyplot.plot(values[:, group])
    pyplot.title(dataset.columns[group], y=0.5, loc='right')
    i += 1
pyplot.show()
#print(values)

# integer encode direction
encoder = LabelEncoder()
values[:,4] = encoder.fit_transform(values[:,4])

```


RecDate	Average Daily Load	AVER TEMP(Celsious)	Rain(mm)	max Uw (Km/h)	\
1/1/2014	5415.13	7.5	6.9	9.3	
1/2/2014	5496.13	9.5	0.3	8.5	
1/3/2014	5787.54	9.1	0.0	4.9	
1/4/2014	5661.46	8.6	0.0	9.5	
1/5/2014	5496.54	9.5	0.0	7.2	

RecDate	Wind distance (km)
1/1/2014	53.4
1/2/2014	58.6
1/3/2014	43.5
1/4/2014	64.9
1/5/2014	65.2

Εικόνα 34: Εισαγωγή δεδομένων και τύπωση δείγματος αυτών

Στην Εικόνα 35 παρατηρούμε τις γραφικές παραστάσεις του ηλεκτρικού φορτίου, της θερμοκρασίας, του πάχους της βροχής, της μέγιστης ταχύτητας του ανέμου και της μέγιστης απόστασης του ανέμου από το σταθμό μετεωρολογικών δεδομένων. Μπορούμε να παρατηρήσουμε την εποχικότητα πολύ εύκολα τόσο στην χρονοσειρά του ηλεκτρικού φορτίου όσο και σε αυτή της θερμοκρασίας. Επίσης, φαίνεται η εξάρτηση των δύο αυτών χρονοσειρών όπου σε πολύ υψηλές ή πολύ χαμηλές θερμοκρασίες η κατανάλωση ηλεκτρικού φορτίου εμφανίζει τις μέγιστες τιμές του. Τέτοιες συσχετίσεις μεταξύ χρονοσειρών είναι πολύ σημαντικές στην διαδικασία πρόβλεψης όχι μόνο για το ηλεκτρικό ρεύμα αλλά γενικότερα στην προσπάθεια πρόβλεψης με νευρωνικά δίκτυα καθώς είναι πληροφορία την οποία το δίκτυο μπορεί να εκμεταλευτεί ώστε να παράγει πιο σταθερές και υψηλότερης ακρίβειας προβλέψεις.



Εικόνα 35: Γραφικές παραστάσεις δεδομένων φορτίου, θερμοκρασίας, μεγέθους σταγόνων βροχής, μέγιστης ταχύτητας ανέμου

Στη συνέχεια συνδέουμε το σετ δεδομένων με την ακολουθία που κατασκευάσαμε (εικόνα 36) και τροποποιούμε τα δεδομένα στο διάστημα [0,1]. Διαχωρίζουμε το σετ δεδομένων σε σετ εκμάθησης και σετ δοκιμής κρατώντας περίπου το 80% για εκμάθηση και το 20% για δοκιμή. Μετά από αυτή τη διαδικασία έχουμε 1462 τιμές σαν δεδομένα εκμάθησης και 173 τιμές σαν δεδομένα δοκιμής. Και σε αυτή την περίπτωση κανονικοποιούμε τα δεδομένα μεταξύ του διαστήματος [0,1] ώστε τα δεδομένα εισόδου να είναι συγκρίσιμα μεταξύ τους.

```
# ensure all data is float
values = values.astype('float32')
# normalize features
scaler = MinMaxScaler(feature_range=(0, 1))
scaled = scaler.fit_transform(values)
# frame as supervised learning
reframed = series_to_supervised(scaled, 1, 1)
# drop columns we don't want to predict
print(reframed.head())
reframed.drop(reframed.columns[[6,7,8,9]], axis=1, inplace=True)
print(reframed.head())
```

	var1(t-1)	var2(t-1)	var3(t-1)	var4(t-1)	var5(t-1)	var1(t)	var2(t)
1	0.485560	0.234501	0.064126	0.186	0.076786	0.550311	0.288410
2	0.550311	0.288410	0.002788	0.170	0.100893	0.571375	0.277628
3	0.571375	0.277628	0.000000	0.098	0.045536	0.542322	0.264151
4	0.542322	0.264151	0.000000	0.190	0.128571	0.504319	0.288410
5	0.504319	0.288410	0.000000	0.144	0.130357	0.523581	0.363881

	var3(t)	var4(t)	var5(t)
1	0.002788	0.170	0.100893
2	0.000000	0.098	0.045536
3	0.000000	0.190	0.128571
4	0.000000	0.144	0.130357
5	0.011152	0.178	0.097321

	var1(t-1)	var2(t-1)	var3(t-1)	var4(t-1)	var5(t-1)	var1(t)
1	0.485560	0.234501	0.064126	0.186	0.076786	0.550311
2	0.550311	0.288410	0.002788	0.170	0.100893	0.571375
3	0.571375	0.277628	0.000000	0.098	0.045536	0.542322
4	0.542322	0.264151	0.000000	0.190	0.128571	0.504319
5	0.504319	0.288410	0.000000	0.144	0.130357	0.523581

Εικόνα 36: Εισαγωγή των δεδομένων στην μορφή ακολουθίας που κατασκευάσαμε και κανονικοποίηση αυτών στο διάστημα [0, 1]

```
# split into train and test sets
values = reframed.values
n_train_days = 365 * 4
train = values[:n_train_days, :]
test = values[n_train_days:, :]
# split into input and outputs
train_X, train_y = train[:, :-1], train[:, -1]
test_X, test_y = test[:, :-1], test[:, -1]
# reshape input to be 3D [samples, timesteps, features]
train_X = train_X.reshape((train_X.shape[0], 1, train_X.shape[1]))
test_X = test_X.reshape((test_X.shape[0], 1, test_X.shape[1]))
print(train_X.shape, train_y.shape, test_X.shape, test_y.shape)
```

(1460, 1, 5) (1460,) (173, 1, 5) (173,)

Εικόνα 37: Διαχωρισμός του σετ δεδομένων σε σετ εκμάθησης και σετ δοκιμής

Στο επόμενο βήμα κατασκευάζουμε το μοντέλο LSTM που θα χρησιμοποιήσουμε για να προβλέψουμε τις τιμές φορτίου. Μετά από πολλές δοκιμές, όσον αφορά τις υπερπαραμέτρους (hyper-parameters) του μοντέλου, με την διαδικασία δοκιμής σφάλματος (trial and error) οι υπερπαραμέτροι του συγκεκριμένου νευρωνικού μοντέλου που κρίνονται ως οι καταλληλότεροι είναι για το κρυμμένο στρώμα (hidden layer) 20 νευρώνες, για τις επαναλήψεις (εποχές) 100 και για τον όγκο δεδομένων 50 (batch size). Το στατιστικό σφάλμα μεταξύ των δεδομένων εκμάθησης και δοκιμής ξεκινάει από το 10% περίπου στην πρώτη επανάληψη και στην τελευταία επανάληψη φτάνει στο 0.6 % το οποίο είναι ένα μικρό ποσοστό μέσου τετραγωνικού σφάλματος (MRSE - Mean Root Squared Error) το οποίο μας δείχνει ότι το μοντέλο συμπεριφέρεται αρκετά ικανοποιητικά. Χρησιμοποιώντας την συνάρτηση *.predict()* προβλέπουμε τις τιμές για το σετ δοκιμής και υπολογίζουμε το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NRMSE) μεταξύ των τιμών το οποίο είναι 4.8%. Επίσης υπολογίζουμε το συντελεστή προσδιορισμού  $R^2$  ο οποίος είναι ίσος με 0.753. Και το στατιστικό σφάλμα αλλά και ο συντελεστής προσδιορισμού έχουν ικανοποιητικές τιμές ένα δείγμα ότι το μοντέλο μπορεί να προβλέψει αξιόπιστα.

```
# design network
model = Sequential()
model.add(LSTM(20, input_shape=(train_X.shape[1], train_X.shape[2])))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer='adam')
# fit network
history = model.fit(train_X, train_y, epochs=100, batch_size=50, validation_data=(test_X, test_y), verbose=2, shuffle=
# plot history
plt.plot(history.history['loss'], label='train')
plt.plot(history.history['val_loss'], label='test')
plt.legend()
plt.show()
```

Εικόνα 38: Κατασκευή Νευρωνικού δικτύου LSTM και σχεδίαση σφάλματος μεταξύ δεδομένων εκμάθησης και δεδομένων δοκιμής

```
# make a prediction
yhat = model.predict(test_X)
test_X = test_X.reshape((test_X.shape[0], test_X.shape[2]))
# invert scaling for forecast
inv_yhat = concatenate((yhat, test_X[:, 1:]), axis=1)
inv_yhat = scaler.inverse_transform(inv_yhat)
inv_yhat = inv_yhat[:,0]
# invert scaling for actual
test_y = test_y.reshape((len(test_y), 1))
inv_y = concatenate((test_y, test_X[:, 1:]), axis=1)
inv_y = scaler.inverse_transform(inv_y)
inv_y = inv_y[:,0]
# calculate RMSE
rmse = sqrt(mean_squared_error(inv_y, inv_yhat))
print('Test RMSE: %.3f' % rmse)
print(inv_y)
print(inv_yhat)
```

Εικόνα 39: Πρόβλεψη τιμών και ανακατασκευή δεδομένων

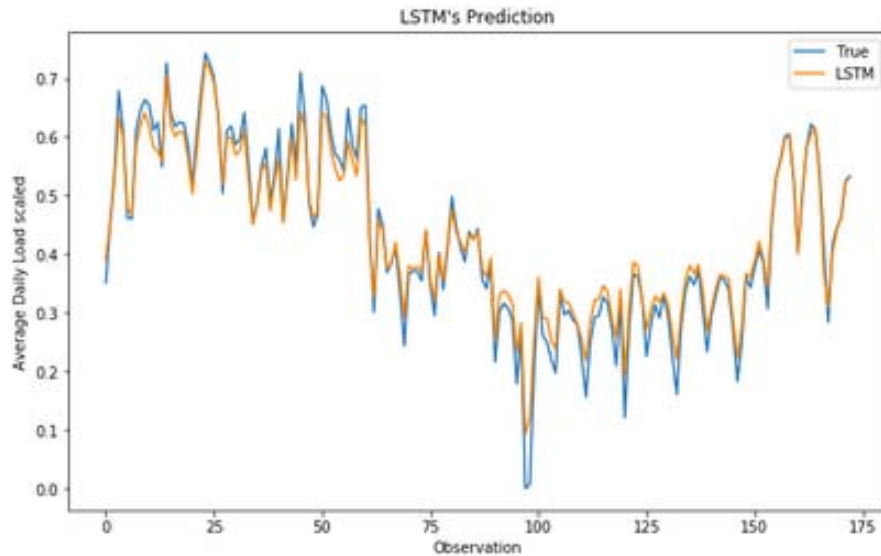
Στην εικόνα 39 γίνεται η πρόβλεψη και επαναφέρουμε τα δεδομένα στην πραγματική τους μορφή στην οποία ήταν πριν την κανονικοποίησή τους.

```
from sklearn.metrics import r2_score

print("The R2 score on the Test set is:\t{:0.3f}".format(r2_score(test_y , yhat)))


The R2 score on the Test set is:          0.753
```

Εικόνα 40: Συντελεστής προσδιορισμού στο διάστημα [0, 1]



Εικόνα 41: Γραφική παράσταση προβλεπόμενων και πραγματικών τιμών για σετ δοκιμής 173 ημερών

Μετά την διαδικασία εκμάθησης βάζουμε το μοντέλο να προβλέψει τις επόμενες 33 μέρες παρουσιάζουμε την γραφική παράσταση και εξάγουμε τα κανονικοποιημένο μέσο τετραγωνικό σφάλμα πρόβλεψης (NRMSE).



Εικόνα 42: Γραφική παράσταση προβλεπόμενων και πραγματικών τιμών για δεδομένα 1 μήνα

Το μοντέλο όπως μπορούμε να διαπιστώσουμε από το μικρό ποσοστό σφάλματος πρόβλεψης καθώς και από την γραφική παράσταση (εικόνα 42) προβλέπει σε ικανοποιητικό βαθμό. Το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NRMSE) μεταξύ των προβλεπόμενων και κανονικών τιμών είναι 9.8% σε χρονικό ορίζοντα ενός μήνα.



Αξίζει να τονίσουμε ότι σε κάθε νέα μέρα που προβλέπουμε δεν αντικαθιστούμε τα δεδομένα εισόδου καθώς κατά την δοκιμή αυτής της τεχνικής το στατιστικό σφάλμα αυξάνοταν συνεχώς.

## 5.5 Νευρωνικό δίκτυο LSTM πολλαπλών κρυφών επιπέδων - μονομεταβλητό (Multi Layer LSTM)

Το τελευταίο μοντέλο που θα κατασκευάσουμε είναι ένα νευρωνικό δίκτυο εκμάθησης Deep Learning. Είναι ουσιαστικά ένα επαναληπτικό νευρωνικό δίκτυο LSTM το οποίο όμως αποτελείται από τέσσερα κρυμμένα στρώματα (hidden layers) LSTM αποτελούμενα το καθένα από 50 νευρώνες αριθμός ο οποίος αποφασίστηκε να χρησιμοποιηθεί μετά από διαδικασίες δοκιμής σφάλματος (trial and error) ως ο βέλτιστος. Το μοντέλο είναι μονομεταβλητό (φορτίο). Αρχικά εισάγουμε τις βιβλιοθήκες και το σετ δεδομένων στο περιβάλλον python. Στη συνέχεια κανονικοποιούμε τα δεδομένα μας στο διάστημα [0,1] και κατασκευάζουμε την ακολουθία εισόδων, εξόδων για το μοντέλο η οποία σε αυτή την περίπτωση μοντέλου διαφέρει σε σχέση με τα προηγούμενα. Θα χρησιμοποιήσουμε συρόμενο παράθυρο παρατηρήσεων ως δεδομένα εισόδου ώστε να πάρουμε σαν έξοδο την επόμενη τιμή. Χωρίζουμε το σετ δεδομένων σε σετ εκμάθησης και σετ δοκιμής. Υπολογίζουμε το στατιστικό σφάλμα μεταξύ των προβλεπόμενων και πραγματικών τιμών και παρουσιάζουμε την γραφική παράσταση μεταξύ αυτών.

```
import pandas as pd
import numpy as np
import keras as kr
import tensorflow as tf
%matplotlib inline
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import r2_score
from keras.models import Sequential
from keras.layers import Dense
from keras.callbacks import EarlyStopping
from keras.optimizers import Adam
from keras.layers import LSTM
from matplotlib import pyplot
from numpy import array

Using TensorFlow backend.
```

Εικόνα 43: Εισαγωγή κατάλληλων βιβλιοθηκών στο περιβάλλον python

Στην Εικόνα 43 γίνεται η εισαγωγή των κατάλληλων βιβλιοθηκών και πακέτων pandas, numpy, keras, tensorflow, sci kit learn τα οποία είναι κατάλληλα για την κατασκευή νευρωνικών δικτύων και τεχνικών μηχανικής μάθησης.

```
dataset_train = pd.read_csv('DATATABLE2.csv')
training_set = dataset_train.iloc[:,1:2].values
```

Εικόνα 44: Εισαγωγή δεδομένων και ορισμός μόνο της στήλης του φορτίου ως ενεργή

Στην Εικόνα 44 εισάγουμε τα δεδομένα και κρατάμε ενεργή μόνο την στήλη του φορτίου από τα δεδομένα που έχουμε στην διάθεση μας για την κατασκευή μονομεταβλητού νευρωνικού δικτύου.

```

X_train = []
Y_train = []
for i in range(60, 1460):
    X_train.append(training_set_scaled[i-60:i,0])
    Y_train.append(training_set_scaled[i, 0])
X_train, Y_train = np.array(X_train), np.array(Y_train)

X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], 1))

```

Εικόνα  
να  
45:  
Κατα  
σκευ  
ή της  
ακολ  
ουθία

ς εισόδου εξόδου

Στην Εικόνα 45 γίνεται η κατασκευή της ακολουθίας εισόδου εξόδου των δεδομένων. Επειδή τα μοντέλα LSTM διαθέτουν μνήμη και μπορούν να εκμεταλευτούν μακροχρόνια ιστορικά δεδομένα για εκμάθηση στο συγκεκριμένο μοντέλο θα κατασκευάσουμε μια ακολουθία συρρώμενου παραθύρου 60 παρατηρήσεων ώστε να προβλεφθεί η 61 παρατήρηση.

```

from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Flatten
from keras.layers import Dropout

```

Εικόνα 46: Επιπλέον εισαγωγή βιβλιοθηκών και πακέτων

Στην Εικόνα 46 γίνεται επιπλέον εισαγωγή πακέτων από τις βιβλιοθήκες για την κατασκευή του νευρωνικού. Προσοχή χρειάζεται η εισαγωγή του πακέτου Dropout καθώς είναι αυτό το οποίο δημιουργεί τα επιπλέον κρυμμένα επίπεδα στην κατασκευή του νευρωνικού δικτύου LSTM πολλαπλών επιπέδων.

```

regressor = Sequential()

regressor.add(LSTM(units = 50, return_sequences = True, input_shape = (X_train.shape[1], 1)))
regressor.add(Dropout(0.2))

# Adding a second LSTM Layer and some Dropout regularisation
regressor.add(LSTM(units = 50, return_sequences = True))
regressor.add(Dropout(0.2))

# Adding a third LSTM Layer and some Dropout regularisation
regressor.add(LSTM(units = 50, return_sequences = True))
regressor.add(Dropout(0.2))

# Adding a fourth LSTM Layer and some Dropout regularisation
regressor.add(LSTM(units = 50, return_sequences = True))
regressor.add(Dropout(0.2))

regressor.add(Flatten())

# Adding the output Layer
regressor.add(Dense(units = 1))

#Compiling the RNN
regressor.compile(optimizer = 'adam', loss = 'mean_squared_error')

# Fitting the RNN to the Training set
regressor.fit(X_train, Y_train, epochs = 100, batch_size = 20)

Epoch 1/100

```

Εικόνα 47: Κατασκευή νευρωνικού δικτύου βαθιάς εκμάθησης Deep learning

Στην Εικόνα 47 γίνεται η κατασκευή του μονομεταβλητού νευρωνικού δικτύου βαθιάς εκμάθησης LSTM. Ορίζουμε το πρώτο κρυφό επίπεδο LSTM 50 νευρώνων (units) και στέλνουμε τα δεδομένα εισόδου μέσω του input shape. Ορίζουμε με το Dropout να χάνεται ένα 20% της πληροφορίας του νευρωνικού κατά την εκμάθηση έτσι ώστε να αποφύγουμε την υπέρ εφαρμογή (overfitting) του μοντέλου τεχνική η οποία θεωρείται συνηθισμένη από τους προγραμματιστές στην κατασκευή νευρωνικών δικτύων πολλαπλών επιπέδων. Στην συνέχεια ακολουθώντας την ίδια διαδικασία προσθέτουμε το δεύτερο το τρίτο και το τέταρτο κρυφό επίπεδο και καταλήγουμε στο τελευταίο επίπεδο όπου ορίζουμε νευρώνα 1 εξόδου (Dense). Το μέσο τετραγωνικό σφάλμα (RMSE) για την εκμάθηση των δεδομένων στην πρώτη επανάληψη ανέρχεται στο 4% περίπου. Στο τέλος της διαδικασίας εκμάθησης μειώνεται αισθητά στο 0.4%. Το νευρωνικό δίκτυο συμπεριφέρεται σωστά καθώς το στατιστικό σφάλμα μειώνεται συνεχώς κατά την διαδικασία εκμάθησης των δεδομένων. Επίσης έστω και αν αναφερόμαστε στο στατιστικό σφάλμα της διαδικασίας εκμάθησης το νευρωνικό δίκτυο βαθιάς εκμάθησης έχει το μικρότερο σφάλμα σε σχέση με τα άλλα δύο μοντέλα.

```
dataset_test = pd.read_csv('DATATABLE4test.csv')
test_set = dataset_test.iloc[:,1:2].values
```


Εικόνα 48: Εισαγωγή σετ δεδομένων δοκιμής

Στο επόμενο βήμα Εικόνα 49 γίνεται η πρόβλεψη από το νευρωνικό δίκτυο χρησιμοποιώντας την συνάρτηση **.predict** ( ) όπου εισάγουμε τα δεδομένα δοκιμής. Κάνουμε αντιστροφή της κανονικοποίησης ώστε τα δεδομένα στην γραφική παράσταση αλλά και στην περίπτωση που χρειαστεί να εξαχθούν να παρουσιάζονται στην πραγματική τους τιμή και όχι εντός του διαστήματος [0,1].

```
#Predict
from numpy import concatenate
from pandas import concat

dataset_total = pd.concat((dataset_train['Average Daily Load'], dataset_test['Average Daily Load']), axis = 0)
inputs = dataset_total[len(dataset_total) - len(dataset_test) - 60:].values
inputs = inputs.reshape(-1, 1)
inputs = sc.transform(inputs)
X_test = []
for i in range (204, 234):
    X_test.append(inputs[i-60:i, 0])
X_test = np.array(X_test[:])
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], 1))
predicted_load_price = regressor.predict(X_test)
predicted_load_price = sc.inverse_transform(predicted_load_price)
```

Εικόνα 49: Πρόβλεψη τιμών για το σετ παρατηρήσεων δοκιμής




Εικόνα 50: Γραφική παράσταση προβλεπόμενων και πραγματικών τιμών

Υπολογίζουμε το κανονικοποιημένο μέσο τετραγωνικό σφάλμα (NRMSE), μεταξύ των προβλεπόμενων και των πραγματικών τιμών, η τιμή του οποίου υπολογίζεται 3.3%. Παρατηρούμε (Εικόνα 50) ότι το μοντέλο νευρωνικού δικτύου πολλαπλών στρωμάτων LSTM (Deep Learning) μπορεί να προβλέψει άνω του ικανοποιητικού την τάση αυτού για ορίζοντα πρόβλεψης ενός μήνα περίπου. Επίσης είναι αρκετά συνεπές στις μεταβολές τιμών. Ουσιαστικά παρατηρώντας το γράφημα είναι λίγες οι περιπτώσεις όπου το μοντέλο νευρωνικού δικτύου πολλαπλών στρωμάτων δεν ακολουθεί τις πραγματικές τιμές ή έχουμε περιπτώσεις αντίθετης τάσης στην πρόβλεψη.

## 5.6 Σύγκριση αποτελεσμάτων

Στο κεφάλαιο αυτό παρουσιάζονται τα διαγράμματα μεταξύ των προβλεπόμενων και των πραγματικών τιμών για τα τα τρία είδη νευρωνικών δικτύων του πέμπτου κεφαλαίου για ορίζοντα πρόβλεψης εύρους 10 ημερών και 20 ημερών. Χρησιμοποιήσαμε αυτά τα εύρη χρονικού ορίζοντα καθώς σύμφωνα με τον μέγιστο εκθέτη Lyapunov ο οποίος από την σχέση  $1 / \lambda_{max}$  όπως αναφέραμε σε προηγούμενο κεφάλαιο δείχνει ποιος είναι ο


ασφαλής ορίζοντας πρόβλεψης της χρονοσειράς. Ο ορίζοντας πρόβλεψης για την χρονοσειρά κατανάλωσης φορτίου που έχουμε στην διάθεση μας είναι 11 μέρες περίπου. Επιπλέον εξάγαμε προβλέψεις για μεγαλύτερο χρονικό ορίζοντα, 20 ημερών, ώστε να ελέγξουμε την συμπεριφορά των τριών μοντέλων σε ένα μεγαλύτερο και όχι τόσο ασφαλή ορίζοντα ώστε να ελέγξουμε την απόδοση των μοντέλων. Παρακάτω παρουσιάζονται διαγράμματα προβλέψιμων τιμών με τις πραγματικές καθώς και ο πίνακας σφαλμάτων.



Εικόνα 51: Γραφική παράσταση πρόβλεψης για ορίζοντα 10 ημερών

Στην Εικόνα 51 μπορούμε να παρατηρήσουμε την συμπεριφορά των τριών μοντέλων πρόβλεψης σε σχέση με τις πραγματικές τιμές για ορίζοντα 10 ημερών. Το μοντέλο πολλαπλών στρωμάτων εκμάθησης LSTM (ML LSTM) είναι αυτό το οποίο ακολουθεί καλύτερα τις πραγματικές τιμές. Είναι πιο ακριβές στις τιμές πρόβλεψης φορτίου και αντιλαμβάνεται καλύτερα τάσεις και μεταβολές της χρονοσειράς σε σχέση με τα άλλα δύο μοντέλα τα οποία όπως φαίνεται έχουν μια σημαντική καθυστέρηση στο να αντιληφθούν τις ακραίες μεταβολές της χρονοσειράς.

Το κανονικοποιημένο μέσο τετραγωνικό σφάλμα μεταξύ των προβλεπόμενων τιμών και των πραγματικών τιμών παρατηρούμε (Πίνακας 1) ότι έχει την μικρότερη τιμή για το μοντέλο νευρωνικού δικτύου βαθιάς εκμάθησης LSTM. Τα στατιστικά σφάλματα είναι μικρά και κάτω του 10% για ορίζοντα πρόβλεψης 10 ημερών. Υπάρχει συμφωνία μεταξύ των αποτελεσμάτων και της βιβλιογραφίας καθώς από αυτή γνωρίζουμε ότι μοντέλα με δομή βαθιάς εκμάθησης (Deep Learning) είναι αυτά τα οποία είναι και τα βέλτιστα για την πρόβλεψη χρονοσειρών (Lago, et. al, 2018).



Εικόνα 52: Γραφική αναπαράσταση μεταξύ προβλεπόμενων και πραγματικών τιμών

Στην εικόνα 52 παρατηρούμε τις προβλεπόμενες τιμές φορτίου σε σχέση με τις πραγματικές για ορίζοντα 20 ημερών δηλαδή μιας εβδομάδας και δύο ημερών περισσότερο σε σχέση με την εικόνα 51. Αυτό που παρατηρούμε είναι ότι το σφάλμα μέτρησης για το επαναληπτικό νευρωνικό δίκτυο LSTM καθώς και για το νευρωνικό δίκτυο βαθιάς εκμάθησης έχει ελαττωθεί κατά την αύξηση του ορίζοντα πρόβλεψης ενώ το στατιστικό σφάλμα για το απλό νευρωνικό δίκτυο έχει αυξηθεί ραγδαία στο 11.5%. Παρατηρούμε ότι αυξάνοντας τον ορίζοντα πρόβλεψης τα πιο σύνθετα νευρωνικά δίκτυα συμπεριφέρονται καλύτερα στην πρόβλεψη τιμών φορτίου σε σχέση με το απλό μονομεταβλητό νευρωνικό δίκτυο πρόσθιας τροφοδότησης. Αυτό είναι κάτι λογικό καθώς τα νευρωνικά δίκτυα απλής δομής όπως το ANN πρόσθιας τροφοδότησης είναι νευρωνικά δίκτυα τα οποία χρησιμοποιούνται όταν στην διάθεση μας έχουμε μικρό όγκο δεδομένων και δεν είναι τα κατάλληλα για προβλέψεις σε μεγάλο χρονικό ορίζοντα. Από την άλλη νευρωνικά δίκτυα όπως είναι τα LSTM δίκτυα και νευρωνικά δίκτυα βαθιάς εκπαίδευσης (DL) λόγω του πλεονεκτήματος της μνήμης και των πολλαπλών κρυφών στρωμάτων έχουν πολύ καλύτερη συμπεριφορά σε προβλήματα προβλέψεων. Το στατιστικό σφάλμα του 3.3% για το νευρωνικό δίκτυο DL το καθιστά το πιο ικανό από τα τρία μοντέλα που χρησιμοποιήσαμε για να εξετάσουμε το πρόβλημα της πρόβλεψης του ηλεκτρικού φορτίου στην Ελλάδα.

Model	RMSE	NRMSE
ANN +10 ημέρες	325.3	6%
LSTM +10 ημέρες	302.5	5.5%
ML LSTM +10 ημέρες	193.3	3.5%
ANN +20 ημέρες	381.5	11.5%
LSTM +20 ημέρες	296.5	5.4%
ML LSTM +20 ημέρες	181.3	3.2%

Πίνακας 1: Μέσο τετραγωνικό σφάλμα και κανονικοποιημένο μέσο τετραγωνικό σφάλμα μεταξύ προβλεπόμενων και πραγματικών τιμών για ορίζοντα δέκα και είκοσι ημερών

## 6 ΣΥΜΠΕΡΑΣΜΑΤΑ

Στην παρούσα διπλωματική εργασία ερευνήθηκε η πρόβλεψη της κατανάλωσης ηλεκτρικού φορτίου στον ελλαδικό χώρο με την χρήση μηχανικής μάθησης και συγκεκριμένα νευρωνικών δικτύων. Κατασκευάστηκαν τρία νευρωνικά μοντέλα πρόβλεψης ένα μονομεταβλητό ANN ένα πολυμεταβλητό LSTM και ένα μονομεταβλητό πολλών κρυφών επιπέδων LSTM (ML LSTM). Για ορίζοντα πρόβλεψης 10 ημερών και τα τρία μοντέλα είχαν μια αξιόπιστη συμπεριφορά στην πρόβλεψη με το ML LSTM να παρουσιάζει καλύτερη συμπεριφορά με στατιστικό σφάλμα μόλις 3.5% μεταξύ των προβλεπόμενων . Για ορίζοντα 20 ημερών το ML LSTM μοντέλο συνεχίζει να εξάγει καλύτερες προβλέψεις σε σχέση με τα άλλα δύο ενώ το μονομεταβλητό ANN έχει αυξήσει κατά πολύ το στατιστικό σφάλμα και κρίνεται ακατάλληλο για ορίζοντα πρόβλεψης 20 ημερών. Εκ του αποτελέσματος της έρευνας θα προτείνουμε ως πιο αξιόπιστο μοντέλο αυτό των πολλαπλών στρωμάτων LSTM (ML LSTM), το οποίο είναι ένα νευρωνικό δίκτυο βαθιάς εκμάθησης. Λόγω της πολυπλοκότητας της δομής του σε σχέση με τα άλλα δύο, καθώς και λόγω της μνήμης που διαθέτει είναι πιο ανθεκτικό στα σφάλματα πρόβλεψης κοινώς εξάγει ακριβέστερες προβλέψεις στους δύο χρονικούς ορίζοντες που ερευνήσαμε.

## 7 ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ

Τα νευρωνικά δίκτυα ανήκουν στην κατηγορία την μηχανικής εκμάθησης των οποίων στόχος είναι η πρόβλεψη τιμών με ελαχιστοποίηση του στατιστικού σφάλματος μέσω διαδικασιών που συμβαίνουν στα διάφορα στρώματα (εισόδου, κρυμμένα, εξόδου). Με αυτό τον τρόπο μπορούν να εξάγουν πολύ αξιόπιστες προβλέψεις. Στην παρούσα εργασία αναπτύχθηκαν τρία μοντέλα νευρωνικών δικτύων τα οποία εξήγαν προβλέψεις αρκετά αξιόπιστες. Στα πλαίσια επέκτασης αυτής της έρευνας θα είχε ιδιαίτερο ενδιαφέρον η χρήση συνδυαστικών μοντέλων νευρωνικών δικτύων πρόβλεψης (υβριδικά νευρωνικά δίκτυα). Σύμφωνα με την βιβλιογραφία η μέθοδος συνδυασμού νευρωνικών δικτύων με τεχνικές ασαφούς λογικής ή μηχανών διανυσμάτων υποστήριξης είναι αρκετά αποτελεσματική. Επιπλέον σε διάφορες επιστημονικές εφαρμογές αποδεικνύεται ότι ο συνδυασμός μεθόδων αποδίδει καλύτερα στις προβλέψεις τιμών αφού μπορούμε να εκμεταλλευτούμε τα πλεονεκτήματα των μεθόδων συνδυάζοντας τες στην ανάπτυξη ενός μοντέλου.

# ΒΙΒΛΙΟΓΡΑΦΙΑ

## Ξερόγλωσση Βιβλιογραφία

- Barak, S., & Sadegh, S. S. (2016). *Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm. International Journal of Electrical Power & Energy Systems*, 82, 92–104.
- Bouktif, S., Fiaz, A. Ouni, A. & Serhani, M. (2018). *Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Generic Algorithm: Comparison with Machine Learning Approaches. Energies*, 11(7), 1636.
- Erbach Gregor, *Understanding electricity markets in the EU*
- Fahad M. U., Arbab N., *Factors Affecting Short Term Load Forecasting, Journal of Clean Energy Technologies, Vol. 2, No. 4, 2014*
- Fan S, Mao C, Chen L, *Next-day electricity-price forecasting using a hybrid network, IET Gener Trans Distrib* 2007.
- Goia, A., May, C., & Fusai, G. (2010). *Functional clustering and linear regression for peak load forecasting. International Journal of Forecasting*, 26(4), 700–711.
- He, W. (2017). *Load Forecasting via Deep Neural Networks. Procedia Computer Science*, 122, 308–314.
- Hebb D., *The organisation of behavior*, (1949).
- Hippert, H. S., Pedreira, C. E., & Souza, R. C. (2001). *Neural networks for short-term load forecasting: a review and evaluation. IEEE Transactions on Power Systems*, 16(1), 44–55.
- Hong T., Min Gui, Baran, M. E., & Willis, H. L. (2010). *Modeling and forecasting hourly electric load by multiple linear regression with interactions. IEEE PES General Meeting*.
- Hong, T., Wang, P., & Willis, H. L. (2011). *A Naïve multiple linear regression benchmark for short term load forecasting. 2011 IEEE Power and Energy Society General Meeting*.
- Hongming Yang, & Xianzhong Duan. (n.d.). *Chaotic characteristics of electricity price and its forecasting model. CCECE 2003 - Canadian Conference on Electrical and Computer Engineering. Toward a Caring and Humane Technology (Cat. No.03CH37436)*.
- Kiartzis S.J, Bakirtzis A.G, Petridis V., *Short term load forecasting using neural networks, Aristotle University of Thessaloniki*, 1994.



Kong W. ; Dong Z.Y. ;Jia Y. ; Hill D. ; Zhang Y. ; “*Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network*”, 2017.

Kumar, H., & Saini, S. (2016). *Chaotic characterization of electric load demand time series & load forecasting by using GA trained artificial neural network*. 2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPE5).

Lago, J., De Ridder, F., & De Schutter, B. (2018). *Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms*. *Applied Energy*, 221

Marino, D. L., Amarasinghe, K., & Manic, M. (2016). *Building energy load forecasting using Deep Neural Networks*. *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*.

McCulloch W. S. and Pitts W., *A logical calculus of ideas immanent in nervous activity*, *Bulletin of Mathematical Biophysics*, 5, 115(1943).

Niu D, Liu D, Wu DD. *A soft computing system for day-ahead electricity price forecasting*. *Appl Soft Comput* 2010;

Otavio A.S. Carpinteiro a; Agnaldo J.R. Reis a; Alexandre P.A. da Silva b; *A hierarchical neural model in short-term load forecasting*, 2004

Panapakidis I. P., Dragoumas A. S., *Day – ahead electricity price forecasting via the application of artificial neural network based models* (2016).

Mandal P., Senjyu T., Urasaki N., Funabashi T.; *A neural network based several-hour-ahead electric load forecasting using similar days approach*, 2006

Pitts W. and McCulloch W. S., *Bulletin of Mathematical Biophysics*, 9, 127(1947).

Ranaweera D.K, Hubele N.F, Papalexopoulos A.D; *Application of radial basis function neural network model short-term load forecasting*, 1995

Rosenblatt F. (1958), *The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain*, Cornell Aeronautical Laboratory, *Psychological Review*.

Hong T., Min Gui, Baran, M. E., & Willis, H. L. (2010). *Modeling and forecasting hourly electric load by multiple linear regression with interactions*. IEEE PES General Meeting.

Topalli A. K., Erkmen I.; *A hybrid learning for neural networks applied to short term load forecasting*, 2003

Von Neumann J., *The computer and the brain*, Yale University Press, New Haven (1958).

Velido A., Lisboa P.J.G, Vaughan J., *Neural Networks in business: a survey of applications (1992 – 1998)*, 1999

Voronin, S., & Partanen, J. (2013). *Price Forecasting in the Day-Ahead Energy Market by an Iterative Method with Separate Normal Price and Price Spike Frameworks*. *Energies*, 6(11), 5897–5920.

Widrow, B., Rumelhart, D. E., & Lehr, M. A. (1994). *Neural networks: applications in industry, business and science*. *Communications of the ACM*, 37(3), 93–105.

### Ελληνική Βιβλιογραφία

Ανεξάρτητος Διαχειριστής Μεταφοράς Ενέργειας (ΑΔΜΗΕ), *Μελέτη Επάρκειας Ισχύος*, 2017.

Καμμενάκης Εμμανουήλ-Στέφανος, *Απελευθέρωση της ηλεκτρικής ενέργειας , τιμολογιακές πολιτικές και υπηρεσίες προστιθέμενης αξίας των παροχών ηλεκτρικής ενέργειας στην Ευρώπη*, 2017.

Πρωτοπαπαδάκης Πέτρος, *Η απελευθέρωση της αγοράς ηλεκτρικής ενέργειας στην Ευρώπη*, 2006

Σταματάκης Παναγιώτης, *Πρόβλεψη κατανάλωσης ηλεκτρικού φορτίου με νευρωνικά δίκτυα και γενετικούς αλγόριθμους*, 2008

Λιβιέρης Ιωάννης, *Αποτίμηση μεθόδων εκπαίδευσης τεχνητών νευρωνικών δικτύων και εφαρμογές*, Πανεπιστήμιο Πατρών, 2009

### Χρήσιμες Ιστοσελίδες

[analyticsvidhya.com/blog/2018/09/non-stationary-time-series-python/](https://analyticsvidhya.com/blog/2018/09/non-stationary-time-series-python/)

[el.wikipedia.org/wiki/Νευρώνας](https://el.wikipedia.org/wiki/Νευρώνας)

[en.wikipedia.org/wiki/White\\_noise](https://en.wikipedia.org/wiki/White_noise)

[ec.europa.eu/eurostat/statistics-explained/index.php?title=Electricity\\_price\\_statistics%](https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Electricity_price_statistics%)

[medium.com/explore-artificial-intelligence/an-introduction-to-recurrent-neural-networks-72c97bf0912](https://medium.com/explore-artificial-intelligence/an-introduction-to-recurrent-neural-networks-72c97bf0912)

# ΠΑΡΑΡΤΗΜΑ Α'

## ΔΕΔΟΜΕΝΑ

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
1/1/14	5415.13	7.5	6.9	9.3	53.4	1/25/14	5643.88	11.7	12	15.6	137.5
1/2/14	5696.13	9.5	0.3	8.5	58.6	1/26/14	5507.29	9.1	26.1	17.2	167.8
1/3/14	5787.54	9.1	0	4.9	43.5	1/27/14	6037.33	7.5	0	13	89.3
1/4/14	5661.46	8.6	0	9.5	64.9	1/28/14	6591.71	8.7	21.6	6.2	51.1
1/5/14	5496.54	9.5	0	7.2	65.2	1/29/14	5851.08	10.7	3.9	18	164.5
1/6/14	5580.13	12.3	1.2	8.9	58	1/30/14	6084.88	9.9	0	7.7	72.8
1/7/14	5883.25	12.5	0	19.2	191.1	1/31/14	6238.46	9.3	0	22.6	342.2
1/8/14	5696.33	11.4	0	7.2	55.5	2/1/14	6171.75	7.2	0	21.6	208.9
1/9/14	5673.92	11.4	0	5.1	43.4	2/2/14	5883.17	8.9	0	25.9	300.4
1/10/14	5739.33	11.2	0	14.4	91.9	2/3/14	6301	8.8	0	28.4	436.1
1/11/14	5500.17	12	0	7.5	63.8	2/4/14	6534.58	8	0	16.4	140.8
1/12/14	5166	11.7	0	12.8	76.6	2/5/14	6485.54	8.3	0	11.8	144.2
1/13/14	5962.5	10.9	0	16.1	90.6	2/6/14	6497.08	8.5	12	12.9	69
1/14/14	5971.13	12.2	0	9.7	91	2/7/14	5955.63	11.2	1.8	16.4	175.6
1/15/14	6149.63	12.9	7.2	13.5	97.9	2/8/14	5467.04	12.9	0	12.9	118.7
1/16/14	5834.75	12.1	4.2	7.4	45.6	2/9/14	4973.83	13.6	0	13.7	105.7
1/17/14	5545.83	11.7	0	12.8	78.1	2/10/14	5097.92	13.3	0	11.6	97.1
1/18/14	5652.75	11.1	0	13.4	76.6	2/11/14	5307.29	13.4	0	8.9	73.9
1/19/14	5067.92	13.6	0	12.3	113.9	2/12/14	5428.42	14.7	0	14.4	133.7
1/20/14	5359.83	14.6	0	15.2	112.3	2/13/14	5360.54	12.1	0	10.1	77.3
1/21/14	5383.5	14.5	0	18.5	168.2	2/14/14	5430.25	11.7	0	13.9	95.5
1/22/14	5451.33	11.9	0	17.8	157.8	2/15/14	5012.04	11.1	0	12.8	103.8
1/23/14	5496.46	12.1	0	13.9	110	2/16/14	4638.25	11.3	0	8.2	70.2
1/24/14	5892.71	11.3	3	9.3	57.3	2/17/14	5011.13	12.4	0	12	73.4

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
2/18/14	5082.63	13.6	0	7.4	62.5	3/18/14	4656.5	16	0	9.6	71.6
2/19/14	5204.54	13.1	0	7.8	68.8	3/19/14	4561.92	16.2	0	13.4	97.1
2/20/14	5297.63	13.6	0	8.9	69.9	3/20/14	4478.83	14.9	0	26.8	232.6
2/21/14	5563.21	13.3	0	6	58.9	3/21/14	4518.29	14.6	0	19.5	170.7
2/22/14	5032.5	13.8	0	10.4	64	3/22/14	4476.04	14.1	0	11.2	76.9
2/23/14	4747.67	13.2	0	9.6	90.1	3/23/14	4100.5	14.3	0	11.6	76.6
2/24/14	5717.25	10.5	1.5	22.1	202.6	3/24/14	4699.17	13.9	0	14	82.7
2/25/14	5625.33	9.3	0	11	95.2	3/25/14	4087.54	13.8	0	20.4	238.7
2/26/14	5548.38	9.5	0	8.2	71	3/26/14	4944.5	14.2	0	17.8	136.1
2/27/14	5376.42	10.7	0	9.4	67.3	3/27/14	5009.46	15.4	0	10.7	72.7
2/28/14	5920.17	11.1	4.8	14.1	78.5	3/28/14	4824.88	15.3	0	14.1	129.7
3/1/14	5835.08	11	22.8	12.3	71.3	3/29/14	4675.13	13	0.6	20.6	138.8

3/2/14	4897.67	12	5.1	20.2	143.4	3/30/14	4197.33	11.8	0	21.9	231.6
3/3/14	5266.38	10.9	19.5	13.1	104.6	3/31/14	4665.42	11.8	0	10.7	86.2
3/4/14	5576.25	11.8	6.3	15.7	157	4/1/14	4703.08	13.6	0	10.2	75.8
3/5/14	5542.5	10.8	0	14.3	93.6	4/2/14	4607.88	15.9	0	10.5	62.6
3/6/14	5608.96	10.7	7.8	13.4	86.7	4/3/14	4709.33	16.1	0	11.2	83.1
3/7/14	5729.92	10.9	5.1	10.7	86	4/4/14	4759.08	15	0	11.7	81.5
3/8/14	5268.08	10.4	0.3	20.7	204.1	4/5/14	4643.42	17.2	0	13.5	102.9
3/9/14	5218.5	7.6	1.2	25.9	305.8	4/6/14	4396.08	15.6	3.9	11.2	78.1
3/10/14	5836.71	7.9	0	23.2	221.3	4/7/14	4822.96	14.1	1.2	14.3	90
3/11/14	5981.08	8	0	18.7	143.2	4/8/14	4647.63	14	0	9	60
3/12/14	5417.79	10.2	0	18.3	144.6	4/9/14	4386.5	15.6	0	13.3	93.7
3/13/14	5316.25	10.8	0	15.1	134.5	4/10/14	4725.38	14.5	1.5	15.4	110.5
3/14/14	5148.21	10.8	0	13.2	91.4	4/11/14	4791.04	12.7	2.1	16.3	137.2
3/15/14	4953	11.5	0	12.1	98.5	4/12/14	4528.17	12.8	0.3	13.2	90.3
3/16/14	4453.38	12.9	0	8	54	4/13/14	4445.96	13.6	1.2	13.3	73.5
3/17/14	4737.88	14.7	0	14.6	87.7	4/14/14	4621.21	14.2	0	14	104.9

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
4/15/14	4542.38	14.8	0	14.8	118.2	5/13/14	4528.75	21.1	0	12.4	80.2
4/16/14	5052.88	14.4	0.6	23.6	157.5	5/14/14	4488.25	20.8	0	27.8	225.2
4/17/14	4838.88	12	3.6	11.9	92.2	5/15/14	4443.42	17.8	0	24.9	328.5
4/18/14	4253.79	11.1	6.3	13.9	150	5/16/14	4536.5	16.8	0	22.2	221.1
4/19/14	4587.92	12.9	0	19.9	191.9	5/17/14	4384.75	16.8	0	20.3	192.2
4/20/14	3586.83	15.1	0	13.2	108.6	5/18/14	3922.08	18	0	10.9	106.8
4/21/14	3920.79	16.4	0.9	10.8	66.1	5/19/14	4695.88	17.2	0	12.8	79.8
4/22/14	4382	19.4	0	11.1	71.2	5/20/14	4725.17	19.8	0	11	76
4/23/14	4730.54	20.3	0	10.9	72.6	5/21/14	4537.08	21.3	0	20.2	200.5
4/24/14	4629.29	19.8	0	18.1	158.6	5/22/14	4722.08	22.8	0	17.4	162.1
4/25/14	4626.08	18.3	0	17.3	95.2	5/23/14	4784.08	23	0	15.2	104.9
4/26/14	4605.71	16.1	12.3	10.9	91.1	5/24/14	4708.67	22.9	0	13.7	99.4
4/27/14	4304.38	14.3	11.7	13.7	101.4	5/25/14	4246.46	23.9	0	14.6	80.9
4/28/14	4651	14.8	3.3	16.5	133.6	5/26/14	4814.5	24.7	0	11.6	84.4
4/29/14	4516.92	16.8	0	15.6	188	5/27/14	4909.5	24.3	0	14.2	114.4
4/30/14	4441.21	16.5	0	19.2	184.6	5/28/14	4904.58	24.8	0	16.6	118
5/1/14	3751.33	16.7	0	16	130.8	5/29/14	5034.21	22.8	0	22.9	165.3
5/2/14	4198.58	17.3	0	12	95.6	5/30/14	4747.92	21.1	0	18.9	203.3
5/3/14	4421.54	17	0	17.6	98.7	5/31/14	4431.5	20.8	0.3	19.1	129.4
5/4/14	3974.92	18.6	0	16.8	126.8	6/1/14	4096.96	20.8	0	28.7	110.7
5/5/14	4377.08	17	0.3	10.5	88.4	6/2/14	4635.5	20.4	0	11.7	111.3
5/6/14	4589.71	16	0	19.1	163.3	6/3/14	5001.63	16.9	3	23.3	244.2
5/7/14	4347.58	17	0	13.9	123.3	6/4/14	4874.67	18.2	3.6	12.8	117.7
5/8/14	4370.88	17.6	0	14.3	92.9	6/5/14	4628.88	21.8	0	13	113.4
5/9/14	4330.5	18.1	0	16.5	167.6	6/6/14	4705.13	23	0	13.3	105.1
5/10/14	4341.79	17.9	0	11.7	102.7	6/7/14	4584.79	23.9	0	13.6	83.6
5/11/14	3906.33	19.7	0	11.9	85.3	6/8/14	4272.17	23.9	0	15.9	152.5
5/12/14	4425.33	19.8	0	15.4	133.6	6/9/14	4383.25	24.3	0	21.1	294.4

Date	Av. D.	AV.	Rain	max Uw	Wind	Date	Av. D.	AV.	Rain	max Uw	Wind dis
------	--------	-----	------	--------	------	------	--------	-----	------	--------	----------

	Load	TEM.		(Km/h)	dis (km)		Load	TEM.		(Km/h)	(km)
6/10/14	4848	25.1	0	23	269.9	7/8/14	6528	28.7	0	17.1	113.8
6/11/14	5127.54	26.7	0	16.1	133.6	7/9/14	6500.5	29.4	0	19.1	114.4
6/12/14	5245.17	25.9	0	18.9	188.2	7/10/14	6501.5	28.3	0	17.5	116.4
6/13/14	5317.13	25.7	0	15.4	124.9	7/11/14	6409.71	27.8	0	14.5	126.5
6/14/14	5149.21	26.3	0	13.1	103.1	7/12/14	5762	26.8	0	18.6	165.8
6/15/14	4620.25	23.9	4.5	21.1	93.9	7/13/14	5391.75	26.5	0	13.1	99
6/16/14	5021.92	24.1	0	13.7	92.2	7/14/14	6125.71	27.2	0	8.1	74.2
6/17/14	5491.58	25.4	0	14.5	87.4	7/15/14	5941.13	23.9	14.4	16.9	101.3
6/18/14	5441.96	26.2	0	11.9	85.4	7/16/14	5549.04	23.2	0.6	8.7	77.2
6/19/14	5386.79	26.5	0	14.7	118.4	7/17/14	5674.75	23.9	0	9.6	70.4
6/20/14	5198.58	23.9	1.2	11.3	115.8	7/18/14	5765.88	25.6	0	10.6	60.6
6/21/14	4894.46	23.8	0	12.7	111	7/19/14	5497.38	25.3	0	17.7	81.3
6/22/14	4573.38	23.8	0	11.2	105.6	7/20/14	5062.58	26.3	0	18.1	142.6
6/23/14	5262.21	25.1	0	20.2	145.1	7/21/14	5990.08	28	0	17	139.6
6/24/14	5617.04	26.4	0	11.6	95.6	7/22/14	6327.71	27.9	0	15.7	93.7
6/25/14	5909.08	28.3	0	11.9	86.9	7/23/14	6146.75	27.1	0	15.5	141.4
6/26/14	6225.42	30.5	0	18.2	153.5	7/24/14	6133.38	26.5	0	9.3	79.5
6/27/14	6296.63	30.8	0	12.6	113.2	7/25/14	6180.63	26.8	0	16.4	149.1
6/28/14	5614.5	26.9	0	23.2	274	7/26/14	5732.33	28.2	0	12.9	111.5
6/29/14	5048.5	25.7	0	16.4	124.7	7/27/14	5493.29	28.6	0	12	99.4
6/30/14	5775.13	25.8	0	11	98.6	7/28/14	6398.83	28.9	0	12.9	91
7/1/14	6047.29	27.5	0	14.8	109.4	7/29/14	6676.29	28.8	0	11.4	73.1
7/2/14	6145.5	26.9	0	22.1	227.1	7/30/14	6749.63	29	0	10	89.2
7/3/14	6060.21	27.7	0	15.7	102.6	7/31/14	6591.75	29	0	13.8	102.7
7/4/14	5695.58	25.1	0	17.4	229.2	8/1/14	6126.54	28.4	0	15.9	114.7
7/5/14	5367.42	24.8	0	21.8	232.9	8/2/14	5451.46	26.9	0	17.1	104.6
7/6/14	5084.04	26.5	0	18.1	172.2	8/3/14	5224.17	28.4	0	11.6	99.8
7/7/14	6084.92	27.8	0	15	100.1	8/4/14	6147.04	29.6	0	13	98.1

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
8/5/14	6276.42	29.1	0	15.7	132.3	9/2/14	5561.21	25	0	16.2	132.4
8/6/14	5891.25	27.4	1.2	18.7	98.2	9/3/14	5286.96	25.9	0	13.5	124.3
8/7/14	5330.38	23.7	0.6	13.2	92.5	9/4/14	5332.75	25.4	0	10.3	70.3
8/8/14	5428.42	25.2	0	12.7	71	9/5/14	5269.67	24.7	1.2	9.8	66.7
8/9/14	5159.75	27	0	11.4	69	9/6/14	4947.13	23.4	5.4	10.2	55.2
8/10/14	4896.5	28.2	0	12.6	101.9	9/7/14	4555.29	22.7	0.3	13.9	86.3
8/11/14	5719.42	29.3	0	17.8	131.7	9/8/14	4926.67	23.1	0	9.3	61.4
8/12/14	6058.63	29.8	0	14.5	114.7	9/9/14	5095.63	23.1	0	14.4	58
8/13/14	6169.21	30.3	0	21.7	196.2	9/10/14	4963.83	23.2	0	10.7	65.6
8/14/14	6258.83	29.9	0	13.1	94.9	9/11/14	5012.08	24.1	0	9.1	68.1
8/15/14	5373	30	0	14.5	88.2	9/12/14	5091.25	24.9	0	13.8	82.3
8/16/14	5515.67	30.1	0	10.9	81.6	9/13/14	4831.13	24.7	0	12.3	93.3
8/17/14	5107.38	29	0	18.4	124	9/14/14	4480.46	24.2	0	11.3	96.2
8/18/14	5327.88	24.3	0	19.4	248.2	9/15/14	5014.5	23.1	5.7	13.2	69.8
8/19/14	5512.25	25.5	0	14.3	129.1	9/16/14	5039.04	21.7	15	13.4	58.3
8/20/14	5672.42	25.9	0	11.1	103	9/17/14	4993.67	21.4	0.3	17.7	141.8

8/21/14	5912.75	28.2	0	10.1	82	9/18/14	5020.08	21.3	0	15.7	129.4
8/22/14	6144.21	29.8	0	12.3	87.9	9/19/14	4798.25	21.2	0	12.8	128.3
8/23/14	5884.08	29.8	0	10.7	91.6	9/20/14	4706.21	22	0	9.8	79.2
8/24/14	5599.92	30	0	14	93.9	9/21/14	4414.13	24.6	0	9.3	84.5
8/25/14	6266.75	28.3	0	15.1	141.9	9/22/14	5081.33	26	0	18.2	126.6
8/26/14	6299.63	27	0	20.1	198.1	9/23/14	5194.75	27.2	0	21.1	156.6
8/27/14	6308.17	27.5	0	17.5	93.9	9/24/14	4816.25	20.8	0	12.2	118.3
8/28/14	6341.83	28.9	0	18.3	172.9	9/25/14	5113.38	22	0	12.7	78.5
8/29/14	6020.67	26.9	0	20.5	327.1	9/26/14	4979.21	20.9	3.6	29.2	141.7
8/30/14	5331.75	25.2	0	15	145	9/27/14	4502.75	16.5	0	21.9	173.9
8/31/14	4876.25	25.4	0	12	110.7	9/28/14	4080.54	17.3	0.9	13.2	153.5
9/1/14	5494.13	25.2	0	12.6	89.8	9/29/14	4419.67	18.6	0	20.1	202.7

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
9/30/14	4544.92	19.7	0	12.7	96.1	10/28/14	5136.42	12.6	0	16.7	211.1
10/1/14	4606.83	19.9	0	13.6	83.9	10/29/14	5612.46	13.9	0.9	8.9	48.8
10/2/14	4654.08	20.9	0	15.1	139	10/30/14	5279.42	14.2	0.3	7	38.9
10/3/14	4893	18.7	0	18.3	192.4	10/31/14	5533	12	0	19.9	197.5
10/4/14	4680.46	17.6	0	15.4	174	11/1/14	5209.63	12.4	0	20.8	241.2
10/5/14	4566.08	17.1	0	14.3	107.7	11/2/14	4885.42	12.7	0	15.1	163
10/6/14	4877.54	18.8	0	8.2	57.1	11/3/14	5085.96	12.7	0	17.7	122.8
10/7/14	4996.38	19.8	3.9	12.7	71.1	11/4/14	5250.08	12.5	0	7.8	55.2
10/8/14	4754.92	19	0.3	12.5	86.1	11/5/14	5600.04	14.6	0	9.2	39.6
10/9/14	4604.04	20.4	0	9.7	90.8	11/6/14	5378.08	16.9	0	9	62
10/10/14	4528.46	19.3	0	15.1	91.6	11/7/14	5444.42	17	2.4	10.6	84.9
10/11/14	4340	19.3	0	10.7	73.9	11/8/14	5308.83	15.3	20.1	10.5	99.4
10/12/14	4020.29	18.3	0	9.1	56.2	11/9/14	4731.75	15	0	6.1	36.5
10/13/14	4548.38	18.6	0	6.8	48.6	11/10/14	4986.5	15.4	0	10.5	82.2
10/14/14	4709.04	19.2	0	7.5	53.2	11/11/14	5235.13	14.9	0	11.3	108.6
10/15/14	4850.88	20.2	0	9.2	73.9	11/12/14	5563.92	14.7	0	9.9	75.5
10/16/14	4992.38	22.8	0	14.8	98.8	11/13/14	5408.79	17.1	1.2	8.4	74.1
10/17/14	4995.67	24.4	0	19.1	169.1	11/14/14	5387.5	14.2	15	11.9	66
10/18/14	4582.04	23.7	0	22.7	187.6	11/15/14	5192.79	14.4	0.3	11.8	85.9
10/19/14	4193.63	17.8	0	26.7	300.7	11/16/14	5054.33	12.9	0	5.7	37.5
10/20/14	4543.54	16.8	0	6.9	68.8	11/17/14	5188.33	16.7	0	6.7	41.8
10/21/14	4691	17.4	0	9.2	72.2	11/18/14	5274.33	16.6	0	6.1	49.3
10/22/14	4806.96	18.6	0	13.9	105.4	11/19/14	5294.58	17.8	0	15.5	123.4
10/23/14	4996	18.5	1.8	23.4	293.7	11/20/14	5066.92	15.7	0	11.3	105
10/24/14	5345.88	13.5	63.3	24.8	102.3	11/21/14	5130.13	12.9	0	17.1	123.2
10/25/14	5126.13	12.4	1.8	9.8	50.8	11/22/14	5111.75	11.5	0	11.4	35.9
10/26/14	4918.58	13.3	0	20.1	141.2	11/23/14	5063.71	10.5	0	14	124.4
10/27/14	5221.46	12.8	0	19.5	190.1	11/24/14	5648.17	9.9	0	10.7	73.1

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
------	-------------	----------	------	---------------	---------------	------	-------------	----------	------	---------------	---------------

11/25/14	5865.08	8.5	1.2	22.2	204.3	12/24/14	5571.88	11.3	0	5.4	21.8
11/26/14	6349.33	7.5	0.6	11.4	92.1	12/25/14	4970.33	11.3	0	10	77.7
11/27/14	6372.46	9.2	5.1	11	143.4	12/26/14	5043.83	10.9	1.5	6.2	45
11/28/14	6141.21	11.1	0.6	7.2	70.7	12/27/14	5344.58	8.6	0.3	11.2	70.7
11/29/14	5768.88	14.8	0	8.6	53.7	12/28/14	5610.13	8.6	0.9	20.9	124.2
11/30/14	5213.17	15.5	0.3	6.1	49.3	12/29/14	5717.04	12.4	0.3	33.1	176.4
12/1/14	5629.63	14.4	0.3	7.9	87.3	12/30/14	6461.46	4.7	4.2	19.4	163.8
12/2/14	5714.29	16.1	0.3	11.7	93.1	12/31/14	6885.79	3.1	11.1	40.3	432.4
12/3/14	5602.17	17.4	0.6	19.5	105.8	1/1/15	5860.54	3	5.4	34.2	299.8
12/4/14	5429.13	15.4	6.9	11.6	76.1	1/2/15	5987.46	3	0	28.1	191.6
12/5/14	5617.67	14.3	0	5.5	54	1/3/15	6167.67	4	0	11.2	25.1
12/6/14	5189.38	15.2	43.2	10.6	82.4	1/4/15	5877.08	8.4	0.6	12.2	97.3
12/7/14	5011.96	13.5	2.4	6.3	45.6	1/5/15	6542.79	4.7	3.6	36.7	303.2
12/8/14	5777.33	12.7	31.2	14.5	99	1/6/15	6146.42	1.2	4.2	40.3	217.3
12/9/14	5820.67	11.5	8.4	6.4	51.3	1/7/15	6880.96	1.6	1.5	42.8	310.2
12/10/14	6119.42	10.3	5.7	13.8	149.7	1/8/15	7158.38	2	0.9	13.3	58.3
12/11/14	6306.04	12	27.3	13.4	138.8	1/9/15	6806.75	4	0	12.2	70.1
12/12/14	6071.42	11.7	21.9	25.2	231.4	1/10/15	6198.04	8.9	0	14.8	104.3
12/13/14	5553.17	11.1	0	12.7	74.3	1/11/15	5385.5	11.1	0	9.7	69.5
12/14/14	5328.71	9.4	0	8.5	70.5	1/12/15	6229.88	8.6	8.4	50	249.7
12/15/14	6105.46	9.1	0	7.2	59.1	1/13/15	6362.96	7	3.6	31.7	297.8
12/16/14	6417.46	12	5.7	11.9	68.1	1/14/15	6145.38	8.4	0	9.7	69.3
12/17/14	6400.29	12.8	15.3	16.8	139.5	1/15/15	6101.42	9.1	0	15.7	88.7
12/18/14	6110.04	10.3	0	10.5	50.4	1/16/15	6053.04	9.1	0	14.8	136.7
12/19/14	5856.08	10.3	0	6.1	52.5	1/17/15	5824.33	8.5	0	8.1	71.5
12/20/14	5670.92	10.1	0	13.3	93.2	1/18/15	5759.63	9.9	0.3	7.9	58.7
12/21/14	5482.17	11.1	0	34.9	146.1	1/19/15	5952.58	13.1	0	15.8	129.5
12/22/14	5866.58	8.8	0	30	126.5	1/20/15	5870.54	13.1	0	10.9	71.6

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
1/21/15	5745.04	14.2	0	13.7	78.7	2/18/15	6671.21	1	0	16.4	16.9
1/22/15	5638.5	13.1	0	8.4	71	2/19/15	6544.58	3.6	1.5	4.3	14.1
1/23/15	5642.04	14.1	5.1	18.3	157.7	2/20/15	6201.88	7.3	0	2.9	6.4
1/24/15	5790.67	9.5	4.2	9.2	77	2/21/15	5654.13	9.2	0	10.6	58.6
1/25/15	5099.83	11.5	0.3	10.8	77.9	2/22/15	5692.54	10.2	11.4	18.9	113.2
1/26/15	5971.08	10	9.3	12.1	69.6	2/23/15	5447.67	11.6	8.1	17.1	124
1/27/15	6309.08	8.1	2.1	8.3	53.8	2/24/15	5774.75	10.8	3.3	12.9	59
1/28/15	6142.33	8.5	0.6	9.5	75.7	2/25/15	5710.79	11.3	0	20.1	152.2
1/29/15	6267.5	9.5	5.7	8	103.2	2/26/15	5993.54	10.5	11.1	13.3	94
1/30/15	6039	10.8	0	20	166.2	2/27/15	6191.96	11.5	10.5	25.5	126.8
1/31/15	5760.13	14.1	0	26.5	393.1	2/28/15	5631.92	10.7	0.6	12.8	100.6
2/1/15	4975.75	16.7	0	35.1	454.2	3/1/15	5017.38	11.8	0	19.1	113.5
2/2/15	5589.58	10.7	0	16.4	146.8	3/2/15	5257.58	11.5	0	21.2	129.9
2/3/15	5627.63	8.9	0	15.7	119.4	3/3/15	5191.33	14.4	0	20.4	165.5
2/4/15	5888	10.7	0	15.8	122.5	3/4/15	5151.54	11.8	0	19.1	159.3
2/5/15	5507.46	14.2	0	9.6	71.7	3/5/15	5816.04	11.5	0	17.8	169.9
2/6/15	5711.46	12.7	4.5	18.8	96.3	3/6/15	5874	15.3	1.5	28.2	323.3
2/7/15	5284.58	10.5	0	7.7	17.4	3/7/15	5631.38	10	18	25.2	225

2/8/15	5185.25	9.9	0	13.8	48.7	3/8/15	5337.38	8.9	0	43.4	363.2
2/9/15	6434.96	6.1	7.2	23.7	92.8	3/9/15	6003.38	8.7	0.3	18.7	214.3
2/10/15	6686.63	1.5	6.6	26.8	156.8	3/10/15	6001.46	8.7	0	10.1	98.3
2/11/15	6726.83	1.6	7.8	11.8	40	3/11/15	5921.17	9.7	10.2	13.2	91
2/12/15	6739.29	3.6	0	8.8	32.8	3/12/15	5703.58	9	0.3	12.4	79.7
2/13/15	6592.79	6.1	0	8.9	30	3/13/15	6275.21	7.6	16.8	19.7	185.7
2/14/15	6111	6.6	0	3.5	7.6	3/14/15	5486.92	9.7	0.3	18.4	164.5
2/15/15	5464.04	7.2	0	5.4	14	3/15/15	4891.88	9.9	0	16.2	138.4
2/16/15	6139.08	6.7	0	13.4	50.8	3/16/15	5571.71	10.3	0	26.8	345.6
2/17/15	6660.38	4.7	0	16.9	148.4	3/17/15	5603.21	10	0	25.4	334.6

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
3/18/15	5889.88	7.4	0	23.9	317.2	4/15/15	4492.5	17.1	0	28.5	191.9
3/19/15	5848.54	7.9	0	11.7	89.6	4/16/15	4391.5	15.2	0	14.8	117.6
3/20/15	5733.92	7.4	0.9	28.7	301.3	4/17/15	4264.08	16.9	0	20.9	177.8
3/21/15	5215.63	8.8	0	11.8	107.2	4/18/15	4160.33	18.3	0	17.1	167.6
3/22/15	5303.83	9.2	0.9	15.9	94.7	4/19/15	4094.46	16.6	0	23.9	196.2
3/23/15	5943.25	10.7	5.7	14.6	136.4	4/20/15	4608.13	13.1	0	23.3	269.6
3/24/15	5715.92	11.4	0.3	22.8	271.8	4/21/15	4529	13.7	0	25.4	223.5
3/25/15	5401.96	10.3	8.4	18.1	157.9	4/22/15	4581.21	13.9	0	18	152.6
3/26/15	5933.54	13	20.1	11.7	132.7	4/23/15	4538.08	12.8	0	18.2	225.4
3/27/15	5738.71	14.2	2.4	17	128.9	4/24/15	4650.75	14.1	0	14.6	107.3
3/28/15	5196	12.5	5.1	8.7	79	4/25/15	4532.42	16.1	0	15.6	100.1
3/29/15	4562.63	12.1	0.6	14.7	69.7	4/26/15	4030.5	16.6	0	11.3	91.5
3/30/15	4874.33	12.8	0	24	161.2	4/27/15	4450.58	17.4	0	15	111.6
3/31/15	4829.33	14.2	0.6	25.9	108	4/28/15	4498.5	18.6	0	19.7	167.8
4/1/15	4713.58	15.1	0	17.5	188.1	4/29/15	4557.75	19.5	0	28.7	254.3
4/2/15	4647.75	14.3	0	24.1	176.4	4/30/15	4509.5	18.6	0	16.7	101.8
4/3/15	4884.88	13.1	0	23	161.4	5/1/15	3631.08	18.4	0	14.9	110
4/4/15	4908.75	11.2	0	26.4	184.2	5/2/15	4231.96	18.7	0	22.3	150.7
4/5/15	4946	12.8	0.3	17.5	117.1	5/3/15	3949.71	20	0	13.2	97.9
4/6/15	5006.13	15.4	0.3	23.1	216.2	5/4/15	4446.63	21.1	0	13.5	98.5
4/7/15	5214.79	12.4	0	22.2	235.1	5/5/15	4656.92	22.5	0	11.4	86.8
4/8/15	5561.58	8.2	0.3	34.2	403.6	5/6/15	4722.96	24.2	0	12.4	83.2
4/9/15	5465.25	7.6	13.8	27.3	296.1	5/7/15	4911.46	25.3	0	16.7	101
4/10/15	4274.5	11.3	0	28.7	323	5/8/15	4602.67	22.8	0	21.1	217.3
4/11/15	4483.58	12.9	0	15.5	113.9	5/9/15	4530.83	22.3	0	20.1	219.2
4/12/15	3647.75	15	0	11.1	77.7	5/10/15	3982.38	20.6	0	22.4	275.8
4/13/15	3661.38	16.6	0	13.5	88.8	5/11/15	4517.88	18.5	2.1	23.4	248.7
4/14/15	4363.63	17	0	11.9	83.5	5/12/15	4375.21	18.2	0	33.6	495.6



Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
5/13/15	4490.5	20.2	0	20.1	205.8	6/10/15	4890.75	21.7	0.3	13	76
5/14/15	4577.08	20.1	0	17.8	148.8	6/11/15	4897.08	22.2	0	14.2	90.7
5/15/15	4629.63	21.6	0	17.5	124	6/12/15	4873.58	24.6	0	17	156.2
5/16/15	4551.79	20	0	16.2	127.4	6/13/15	4820	25.8	0	18.1	160.2
5/17/15	4183.75	20.6	0	13.9	93	6/14/15	4610.71	26.8	0	13.3	112
5/18/15	4673.04	22	0	12.3	105.1	6/15/15	5383.63	27.5	0	17.4	115.6
5/19/15	4874.46	21.1	0	15	129.1	6/16/15	5693.83	28.7	0	15.1	117
5/20/15	4780.25	20.9	0	19.1	93.3	6/17/15	5709.75	28.4	0	18.1	135.7
5/21/15	4845.13	22.4	0	14	83.6	6/18/15	5240.79	23.1	15.3	24.1	183.2
5/22/15	5015.96	23.1	0	13.5	74.6	6/19/15	4849.83	21.3	5.7	21.3	150.8
5/23/15	4501.58	23.1	0	14.5	116	6/20/15	4712.96	22.5	0	12.8	100.3
5/24/15	4135.54	21.7	0	17.2	138.1	6/21/15	4296.79	23.5	0	14.1	136.6
5/25/15	4579.25	21.2	0	25.1	192.1	6/22/15	4644.42	20.4	3.3	17.4	145.2
5/26/15	4778.54	20.3	0	16.4	109.3	6/23/15	4748.42	21.5	0	15.2	109.4
5/27/15	4913.21	20.2	3.6	17.1	113	6/24/15	4920.29	23.4	0	12.8	99.6
5/28/15	4840.92	18.2	3.6	11.9	71.5	6/25/15	5098.63	24.8	0	17.3	113.5
5/29/15	4607.88	16.7	0	21.5	206.9	6/26/15	5104.83	23.4	0	15.2	145.6
5/30/15	4357.17	18.4	0	9.6	66.2	6/27/15	4829.96	22	2.7	28.1	240
5/31/15	4011.67	19.7	0	15	104.8	6/28/15	4529.71	22.6	1.8	14.5	101.9
6/1/15	4302.83	20.9	0	17.4	165.1	6/29/15	4990.75	22.7	0.3	14.5	95.6
6/2/15	4611.92	23.1	0	20.2	187.1	6/30/15	5169.46	22.4	12.9	28.3	145.6
6/3/15	4740.5	23.7	0	27.8	271.7	7/1/15	4900.71	22.3	0	17	127.1
6/4/15	4943.17	24.5	0	17.3	181.6	7/2/15	4747.71	24.6	0	21.2	195.1
6/5/15	4910.29	22.4	8.7	20.2	208.9	7/3/15	5015.54	25.5	0	20.8	223.1
6/6/15	4736.79	22.5	0	24.6	342.5	7/4/15	4834.13	24.6	0	19.3	232.2
6/7/15	4440.67	20.7	0	32.4	441.7	7/5/15	4535.29	25.1	0	17.3	155.6
6/8/15	4791.71	21.4	0	21.9	193.8	7/6/15	5358.58	26.8	0	17.1	144.2
6/9/15	4875.04	20.9	0	14.5	107.4	7/7/15	5730.33	27.3	0	23.5	240.7

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
7/8/15	5923.75	29.3	0	21.6	235	8/5/15	6515.71	30.4	0	20.9	199.3
7/9/15	6160.83	27.5	0	14	109.7	8/6/15	6312.96	30.1	0	24.9	248.7
7/10/15	6085.63	28.1	0	20.7	137.8	8/7/15	6193.71	28.8	0	23	274.3
7/11/15	5420.58	26.6	0	17.2	128.2	8/8/15	5501.08	27.9	0	19.3	205.6
7/12/15	4988.79	26.1	0	18.2	160.5	8/9/15	5072.29	28.3	0	19.7	155.8
7/13/15	5827.42	26.6	0	17.1	179.5	8/10/15	5697.04	27.6	0	15.5	89.2
7/14/15	6167.5	28	0	17.6	154.4	8/11/15	5793.29	27.5	0	14.6	76.8
7/15/15	6150.17	27.4	0	20.3	256.8	8/12/15	5981.42	28.6	0	13.3	84.4
7/16/15	6260.54	28.7	0	24.3	290.6	8/13/15	6033.13	28.6	0	14.9	102.1
7/17/15	6228.54	28.7	0	28.6	368.2	8/14/15	5897.42	28.1	0	17.7	113.9
7/18/15	5868.38	28.4	0	28.5	345.5	8/15/15	5039.83	28	0.6	11.1	53.1
7/19/15	5558.17	29.7	0	28.2	357.7	8/16/15	5142.67	28.4	0	13.8	99.1
7/20/15	6408.21	30.6	0	20	210.4	8/17/15	5839.79	29.8	0	20.7	187.3

7/21/15	6904.58	31.2	0	35.5	382.6	8/18/15	5861.17	28.3	0	14.6	102.6
7/22/15	6936.29	30.1	0	31.7	387.6	8/19/15	5927.38	28.4	0	12.8	85.7
7/23/15	6731.5	28.6	0	18.8	185	8/20/15	6012.42	28.9	0	14.7	102.5
7/24/15	6710.13	27.6	0	14.1	111.1	8/21/15	5753.5	27.2	0	22.3	210.1
7/25/15	6328.96	28	0	13.5	107.4	8/22/15	5198.04	26	0	21.6	156.1
7/26/15	5941.75	28.4	1.5	16.1	66.1	8/23/15	4590.92	24.5	0	20.5	173.8
7/27/15	6868.21	29.5	0	13.2	114	8/24/15	5219.5	24.9	0	15.6	164.9
7/28/15	7287.63	30.5	0	14.8	93	8/25/15	5359.54	26.3	0	24.1	244.3
7/29/15	7458.71	31.4	0	12.9	102	8/26/15	5382.29	26.8	0	26.8	254.5
7/30/15	7596.04	31.6	0	15.4	89.3	8/27/15	5387.38	27	0	25.5	230.4
7/31/15	7444.42	32.2	0	15.6	100.8	8/28/15	5408.29	27.3	0	20.7	212.2
8/1/15	6526.33	30.7	0	24.9	247.9	8/29/15	5082.92	28.3	0	21.1	214.7
8/2/15	5955.63	29.5	0	20.2	230.9	8/30/15	4873.71	29.2	0	30.5	434
8/3/15	6550.29	29	0	19.9	219.9	8/31/15	5736.21	28.9	0	26.2	267.7
8/4/15	6554.13	29.4	0	18	123.4	9/1/15	5923.83	28.4	0	13.6	104.3

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
9/2/15	5858	26.3	0	13.7	103.5	9/30/15	4716.96	18.1	0	24.2	326.8
9/3/15	6001.29	27.1	0	11.4	86.5	10/1/15	4585.79	18.1	0	21.9	291
9/4/15	6044.38	28.7	0	11	65.6	10/2/15	4547.42	18.3	0	21.1	218.5
9/5/15	5724.25	29.8	0	14.3	82.2	10/3/15	4314	18.3	0	10	72.1
9/6/15	5534.54	30.9	0	16.8	101.2	10/4/15	4049	19.5	0	8.5	57.1
9/7/15	6130.63	28.9	0	15.6	130.6	10/5/15	4498.33	20.5	5.7	9.6	62.8
9/8/15	5748.13	26.3	0	22.9	203.2	10/6/15	4623.58	21.2	0	9.7	54
9/9/15	5446.88	23.8	0	21.5	326.1	10/7/15	4835.29	21.1	0.6	11	74.2
9/10/15	5334.71	25.5	0	17.4	139.7	10/8/15	4884.38	19.8	0.3	14.1	113.5
9/11/15	5304.58	26.6	0	18.5	125.8	10/9/15	4731.92	19.8	0	10.9	90.5
9/12/15	4676.83	24.6	0	14.6	108.1	10/10/15	4792.13	19	3	14.5	109.1
9/13/15	4288.42	23.8	0	16.1	214.3	10/11/15	4241.71	21	9.6	19.9	97.9
9/14/15	4853.67	24.6	0	17.7	157.5	10/12/15	4468.33	21.1	0	20.2	161.1
9/15/15	4996.46	23.7	0	21	195.4	10/13/15	4488.33	20	0	12.3	98.7
9/16/15	5014.88	24.7	0	19.3	158.3	10/14/15	4677.83	18.1	0	17	240.1
9/17/15	5152.33	25.2	0	14.1	98.3	10/15/15	4713.92	17.8	0	14.6	110.4
9/18/15	5267.04	26.8	0	20.7	143.8	10/16/15	4885.29	16.5	0	14.3	116.4
9/19/15	5010.17	27.9	0	24.3	199.6	10/17/15	4556.83	17.8	0	9.7	104.1
9/20/15	4519.21	24.6	0	16.4	95.7	10/18/15	4324.71	18.6	0	11.7	147.5
9/21/15	4949.92	19.8	38.4	24.9	204	10/19/15	4662.38	19.8	0	13	99.2
9/22/15	4901.33	20	4.5	14.8	148.9	10/20/15	4829.33	20.3	0	8.5	51.6
9/23/15	4819.33	21.3	4.2	8.1	48.7	10/21/15	4962.92	19.9	0	12.7	105.2
9/24/15	4824.21	22.6	0.3	16.5	110.2	10/22/15	5127.46	18.4	107.6	23.1	101.8
9/25/15	4897.29	23.1	0	15	115.3	10/23/15	5126.42	16.3	17.5	39.8	219
9/26/15	4834.83	22.3	2.1	19.8	73.4	10/24/15	4842.17	14.6	1.3	21.5	253.6
9/27/15	4125.5	22.3	3	10.4	70.2	10/25/15	4182.67	14.7	0	22	201.1
9/28/15	4562.08	21.1	30.3	11.7	51.4	10/26/15	4516.13	15	0	14.5	85.1
9/29/15	4701.75	20.7	0.3	18.2	110.5	10/27/15	4732.96	15.6	0	24.5	145.1

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
10/28/15	4402.13	14.3	0	19.2	206.9	11/25/15	5259.92	15.3	41.9	26.1	202.9
10/29/15	4936.71	14	0	15.6	126.2	11/26/15	5189.33	14.8	0	16.2	112.1
10/30/15	5276.04	14.8	0	25.2	213.8	11/27/15	5427.42	14.1	5.1	21.8	123.3
10/31/15	5165.42	14	0	30	474.5	11/28/15	5146.92	13.1	8.4	19.2	197.6
11/1/15	4819.83	13	0	25.4	372.3	11/29/15	4786.46	12.6	0.3	14	106.8
11/2/15	4940.96	13.7	0	19.1	165.5	11/30/15	5215.04	10.9	0	12	105.2
11/3/15	5148.38	14.1	0	9.5	75.8	12/1/15	5515.92	11.1	0	17.8	123.2
11/4/15	5056.04	14.4	0	9.4	87.4	12/2/15	5379.54	13.5	0	14.3	99.3
11/5/15	5107.17	14.1	0	9.9	87.8	12/3/15	5269.29	13.5	0	22.3	110.6
11/6/15	5057	14.4	0	9.4	76.2	12/4/15	5399.38	11.2	0	14.3	142.4
11/7/15	4864.42	14.1	0	7	73.3	12/5/15	5383.17	10	0	21.9	156.3
11/8/15	4487.96	14.6	0	13.6	102	12/6/15	4998.54	10.1	0	6.3	64.9
11/9/15	4830.54	16	0	12.2	98.3	12/7/15	5533.25	10.5	0	7.3	70.3
11/10/15	4965.79	19.6	0	31.8	186.2	12/8/15	5754.83	10.3	0	10.2	85.3
11/11/15	4835.92	19.1	0	9.8	87.6	12/9/15	5874.25	10.2	0	13	87.7
11/12/15	4665.92	18	0	6.3	50.1	12/10/15	6238.17	9.8	0	11	57.9
11/13/15	4752.67	17.6	0	10.3	56.4	12/11/15	6440.75	8.6	2.4	11.4	89.2
11/14/15	4705.42	16.8	0	9.7	79.6	12/12/15	6028	6.9	0.3	16.9	109.6
11/15/15	4441.83	15.2	0	13.2	87.6	12/13/15	5473.54	8.1	0	8.9	74.3
11/16/15	4815.75	15.2	0	13.1	67.8	12/14/15	6046.79	9.3	0	7.3	81.7
11/17/15	4957.54	16.9	0	15.1	136.6	12/15/15	6321.54	8.8	0	13	83.6
11/18/15	5020.92	15.3	0	7	53.3	12/16/15	6447.96	8.5	0	15.2	175.5
11/19/15	5027.88	15.7	0	7.3	55.2	12/17/15	6445.88	8.7	0.3	29.4	361.9
11/20/15	5091.83	14.8	0	13.9	87.1	12/18/15	6254.38	8.8	0	18.9	185.7
11/21/15	5068.21	16.6	0	22.8	228.6	12/19/15	5930.21	6.9	0	7.8	67.8
11/22/15	4535.17	18.5	0	26.6	359.3	12/20/15	5608.63	7.6	0	10.7	87.3
11/23/15	4973.13	18.3	0	18.6	156.7	12/21/15	6051	8.4	0	7.9	77.1
11/24/15	5058.58	17.5	0	11.2	76.7	12/22/15	6060.75	9.5	0	7.3	73.5

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
12/23/15	5885.38	11.2	0	8.1	78.7	1/19/16	6426.67	3.9	0	22.4	178.7
12/24/15	5652.58	12.1	0	7.6	68.7	1/20/16	6847.46	6	10.1	22.8	242.8
12/25/15	4889.58	11.2	0	7.3	65.8	1/21/16	6235.92	7.7	0	9.5	60.2
12/26/15	4848.21	10.8	0	24.1	221.8	1/22/16	6269.67	6.6	0	18.7	147
12/27/15	4994.42	10.9	0	12.9	88.6	1/23/16	6259.83	2.4	3.4	24.2	305.6
12/28/15	5492	10.4	0	7	74.9	1/24/16	5861.92	3	0	13.1	87
12/29/15	5461.58	11.4	0	12.1	75.6	1/25/16	6543	3.2	0	11.4	87.3
12/30/15	6243.08	7.4	1	29.7	386	1/26/16	6549.83	5	0	18.6	108
12/31/15	6574.13	0.9	1	26.7	331	1/27/16	6155.21	7.9	0	8.7	75.2
1/1/16	5495.17	1.5	0	10.2	93.2	1/28/16	5934.75	9.8	0	14.3	94.9
1/2/16	5632.08	5.1	0	7.4	55	1/29/16	5769.63	11.7	0	7.9	66.2
1/3/16	5892	8.8	3.4	18.3	100	1/30/16	5258.25	12.8	0	10.1	86.1
1/4/16	6189.63	11	0.3	14	86.5	1/31/16	4963.96	10.9	0	20.3	136.7
1/5/16	6028.79	15.1	0	8.6	71.6	2/1/16	5208.71	13.6	0	7.8	78.2
1/6/16	5159.38	14.6	0	26.1	150.1	2/2/16	5192.33	14.3	0	10.8	87.3

1/7/16	5578.58	12.7	4.7	25.2	315	2/3/16	5148.33	13.3	0	11.1	100.6
1/8/16	5455.67	10.7	0	10	95.9	2/4/16	5385.29	12.7	2	14.8	148
1/9/16	5322.54	11.1	0	8.8	72	2/5/16	5987.42	7.7	13.2	41.9	223.4
1/10/16	5295.21	10.8	3.4	10.2	69.4	2/6/16	5592.83	5.3	9.1	17.5	129.7
1/11/16	5441.17	13.4	0	16.9	117.5	2/7/16	5277.25	5.8	0	14.1	103.6
1/12/16	5416.38	14.8	0	22.1	169.9	2/8/16	5905	6.7	0	8.1	77.5
1/13/16	5453.96	13.2	0	21.6	175.9	2/9/16	5897.13	9	0	12.3	105.4
1/14/16	5426.17	10.7	0	15.7	109.6	2/10/16	6138.25	11.1	0	20.7	144.6
1/15/16	5764.67	10.7	0	16	96.9	2/11/16	5347.08	14.2	1.4	20.4	174
1/16/16	5740.21	13.9	0.7	32	394.1	2/12/16	5575.79	13.6	0.3	14.1	94
1/17/16	5402.75	10.5	16.2	29.1	234.7	2/13/16	5350.21	14.5	0	21.2	126.4
1/18/16	6354.83	4.3	0	36.2	393.6	2/14/16	4848.25	15.2	0	14.7	88.8

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
2/15/16	4889.46	17.5	0	11.6	90.8	3/13/16	4964.17	14.2	5.4	11.2	114.7
2/16/16	5020.92	17.4	0	7.5	60.2	3/14/16	5098.29	9	22.3	21.8	180.7
2/17/16	5153.79	17.2	0	7.4	61.7	3/15/16	5806.17	7.9	0.3	15.9	203.9
2/18/16	5228.63	17	0	16.5	169.5	3/16/16	5909.42	8.4	0	22.6	302.2
2/19/16	4898.54	16.3	0	14	100.1	3/17/16	5853.33	8.4	0	16.8	161.4
2/20/16	4935.83	13.6	1.4	38.7	196.1	3/18/16	5883.46	8.7	2.4	10.7	75.3
2/21/16	4397.13	11.9	7.1	37.2	183.1	3/19/16	4960.17	12.5	0	15.8	127.5
2/22/16	4849.67	13.5	0	11.5	90.5	3/20/16	4448.54	13.4	0	13.6	91.2
2/23/16	4861.75	14.4	0	10.7	82.6	3/21/16	4841.33	13.4	0	15.3	109.7
2/24/16	5414.83	14	0.3	12.6	88.7	3/22/16	4849.67	15.1	0	23.2	147.1
2/25/16	4965.67	13.4	0	10.8	79.6	3/23/16	5250.67	16.5	0	28.2	264.1
2/26/16	5030.08	13.6	0	14.5	98.7	3/24/16	5121.46	14.9	0	27.9	278.4
2/27/16	4713.75	13.2	0	12.1	84.7	3/25/16	4778.38	11.8	1	31.2	206.9
2/28/16	4442.75	13.5	0	11.6	90.3	3/26/16	4821.46	9.4	0	13.2	132.8
2/29/16	5024.38	15.1	0	12.1	100.2	3/27/16	4977.13	8.5	8.4	13.8	124
3/1/16	4794.83	16.3	0	12.2	84.5	3/28/16	5125.83	9.4	0	13.8	98.7
3/2/16	4876.42	13.2	0	17	110.8	3/29/16	5203.88	12.3	0	15.7	99.3
3/3/16	4961.42	13.2	2.4	20.9	164.9	3/30/16	4799.67	15.4	0	12.4	89.3
3/4/16	5182.33	10.7	2.4	21.8	200.3	3/31/16	4682.38	15.8	0	14.1	98.7
3/5/16	4698.38	11.5	0	17.1	146.7	4/1/16	4664.38	16.4	0	12.2	95.8
3/6/16	4417.46	12.6	0	14.3	131.1	4/2/16	4646.29	16	0	13.1	57.4
3/7/16	4873.13	14.9	0	24.4	209.9	4/3/16	4158.88	16.8	0	20.3	121.8
3/8/16	5005.63	14.8	0	12.4	114.3	4/4/16	4407.33	17.6	0	17.3	127
3/9/16	5364.04	13.1	10.1	17.1	131	4/5/16	4500.96	18.7	0	11.2	83.5
3/10/16	5229.42	11.8	0.3	22.8	204.7	4/6/16	4466.71	19	0	12.8	70.3
3/11/16	5085.83	12.6	0	15	131.5	4/7/16	4552.21	19.5	0	11	82.6
3/12/16	5373.25	12.8	2	16.9	196.4	4/8/16	4529.88	19.7	0	19	140.1

Date	Av. D.	AV.	Rain	max Uw	Wind	Date	Av. D.	AV.	Rain	max Uw	Wind
------	--------	-----	------	--------	------	------	--------	-----	------	--------	------

	Load	TEM.		(Km/h)	dis (km)		Load	TEM.		(Km/h)	dis (km)
4/9/16	4475.08	18.4	0	23	189.5	5/6/16	4326.71	16.4	0	15.3	116.8
4/10/16	4080.04	17.1	0	19.5	205.2	5/7/16	4122.79	17.8	0	13.4	107.3
4/11/16	4465.13	15.8	0	11.8	106	5/8/16	3936.46	19	0	15.9	104.5
4/12/16	4441.13	18.3	0	11.8	108.9	5/9/16	4355.58	19.2	0	12.9	116
4/13/16	4507.46	19.1	0	12.6	93.1	5/10/16	4524.04	20.1	0	13.2	122.2
4/14/16	4615.54	19.8	0	12.1	88.9	5/11/16	4698.29	20.3	0	12.7	93.7
4/15/16	4399.79	20.8	0	11.5	96.9	5/12/16	4877.67	22	0	12.4	79.5
4/16/16	4251.46	19.7	0	14.2	104.2	5/13/16	4558.38	23.9	0	21.3	212.1
4/17/16	3928.63	20.6	0	11.2	76.9	5/14/16	4394.08	21.2	0	16.4	183
4/18/16	4449.96	21.7	0	12	69.9	5/15/16	4116.83	21.4	0	17.8	147.8
4/19/16	4688.79	22.6	0	12.7	89.3	5/16/16	4479.29	21.4	0	25.3	208.9
4/20/16	4550.29	21.5	0	15.8	127.2	5/17/16	4614.42	20.1	0	13.5	111.8
4/21/16	4563.42	15.8	0	33.3	348.5	5/18/16	4609.46	18.7	0	12.2	96.9
4/22/16	4613.75	17	0	17.7	147	5/19/16	4724.13	18.8	0	16.2	137.7
4/23/16	4555.58	17.9	0	14.5	121.2	5/20/16	4919.46	19.1	0.3	14.9	96.9
4/24/16	4177.79	19.5	0	23.4	256.5	5/21/16	4756.67	18.9	2.4	16.5	147.4
4/25/16	4478.67	18.5	0	18.6	220.5	5/22/16	4084.17	17.4	0	18.4	197
4/26/16	4507.42	16.3	0	25.3	262.5	5/23/16	4237.33	20.4	0	14.3	112.7
4/27/16	4537.46	16	0	18.3	129.5	5/24/16	4427.29	21.3	0	18.4	186.1
4/28/16	4439.29	18.4	0	16.7	128.4	5/25/16	4353.88	21.2	0	25.8	212.8
4/29/16	4117.92	19.4	0	14.7	84.6	5/26/16	4449.33	22.5	0	15.4	142.4
4/30/16	4100.42	18.5	0	22.5	231.8	5/27/16	4510.88	23.8	0	13.1	129.8
5/1/16	3404.58	18.7	0	22.3	281.5	5/28/16	4380.54	23	0	13.5	134.5
5/2/16	3689.92	17.1	0.3	17.3	180.8	5/29/16	4192.71	22.8	0	17.4	110
5/3/16	3780.67	15.4	0	19.1	177.6	5/30/16	4768.5	24	0	13.9	104.9
5/4/16	4506	14.9	0	13.2	89.5	5/31/16	4914.96	25.6	0	17.6	107.6
5/5/16	4585.83	15.1	0.7	16.5	112.6	6/1/16	5104.21	27	0	14.3	120.8

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
6/2/16	5069.71	26.4	0	15.3	111	2/29/16	5024.38	15.1	0	12.1	100.2
6/3/16	5005.38	25.3	0	18.5	121.4	3/1/16	4794.83	16.3	0	12.2	84.5
6/4/16	4714.25	24.3	0	13.7	96	3/2/16	4876.42	13.2	0	17	110.8
6/5/16	4393.63	24.5	0	14.8	99.9	3/3/16	4961.42	13.2	2.4	20.9	164.9
6/6/16	4896.33	24.7	0	13	96.2	3/4/16	5182.33	10.7	2.4	21.8	200.3
6/7/16	5025.71	22.2	14.6	21	107.8	3/5/16	4698.38	11.5	0	17.1	146.7
6/8/16	4756.38	20.7	0	22.1	236.4	3/6/16	4417.46	12.6	0	14.3	131.1
6/9/16	4689.04	20.1	0	13.8	110.8	3/7/16	4873.13	14.9	0	24.4	209.9
6/10/16	4838.58	20.8	0	17.3	123.7	3/8/16	5005.63	14.8	0	12.4	114.3
6/11/16	4603.25	22.8	0	13.8	111	3/9/16	5364.04	13.1	10.1	17.1	131
6/12/16	4349.54	24.1	0	20.5	141.5	3/10/16	5229.42	11.8	0.3	22.8	204.7
6/13/16	5019.46	23.3	0	16.6	141.7	3/11/16	5085.83	12.6	0	15	131.5
6/14/16	4934.83	24.6	1	23.5	164.7	3/12/16	5373.25	12.8	2	16.9	196.4
6/15/16	4976.79	25	0	31.7	234.4	3/13/16	4964.17	14.2	5.4	11.2	114.7
6/16/16	5374.54	27.1	0	13.1	106.8	3/14/16	5098.29	9	22.3	21.8	180.7
6/17/16	5723.79	30	0	8.7	81.1	3/15/16	5806.17	7.9	0.3	15.9	203.9

6/18/16	5811.29	32.5	0	8.9	97.2	3/16/16	5909.42	8.4	0	22.6	302.2
6/19/16	5656.75	32.9	0	15.6	116	3/17/16	5853.33	8.4	0	16.8	161.4
6/20/16	5863.71	32.1	0	12.8	105.8	3/18/16	5883.46	8.7	2.4	10.7	75.3
6/21/16	6662.46	32	0	18.6	132.1	3/19/16	4960.17	12.5	0	15.8	127.5
6/22/16	6782.17	31.7	0	21.7	266.7	3/20/16	4448.54	13.4	0	13.6	91.2
6/23/16	6915.46	31.1	0	30.1	320.7	3/21/16	4841.33	13.4	0	15.3	109.7
6/24/16	6952	31.2	0	30.1	352.6	3/22/16	4849.67	15.1	0	23.2	147.1
6/25/16	6296.88	29.7	0	30.2	298.3	3/23/16	5250.67	16.5	0	28.2	264.1
6/26/16	5499.38	27.8	0	16.9	169.2	3/24/16	5121.46	14.9	0	27.9	278.4
6/27/16	6363.88	28.1	0	15.3	115	3/25/16	4778.38	11.8	1	31.2	206.9
6/28/16	6345.92	27	21.2	23.7	122.4	3/26/16	4821.46	9.4	0	13.2	132.8

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
3/27/16	4977.13	8.5	8.4	13.8	124	4/23/16	4555.58	17.9	0	14.5	121.2
3/28/16	5125.83	9.4	0	13.8	98.7	4/24/16	4177.79	19.5	0	23.4	256.5
3/29/16	5203.88	12.3	0	15.7	99.3	4/25/16	4478.67	18.5	0	18.6	220.5
3/30/16	4799.67	15.4	0	12.4	89.3	4/26/16	4507.42	16.3	0	25.3	262.5
3/31/16	4682.38	15.8	0	14.1	98.7	4/27/16	4537.46	16	0	18.3	129.5
4/1/16	4664.38	16.4	0	12.2	95.8	4/28/16	4439.29	18.4	0	16.7	128.4
4/2/16	4646.29	16	0	13.1	57.4	4/29/16	4117.92	19.4	0	14.7	84.6
4/3/16	4158.88	16.8	0	20.3	121.8	4/30/16	4100.42	18.5	0	22.5	231.8
4/4/16	4407.33	17.6	0	17.3	127	5/1/16	3404.58	18.7	0	22.3	281.5
4/5/16	4500.96	18.7	0	11.2	83.5	5/2/16	3689.92	17.1	0.3	17.3	180.8
4/6/16	4466.71	19	0	12.8	70.3	5/3/16	3780.67	15.4	0	19.1	177.6
4/7/16	4552.21	19.5	0	11	82.6	5/4/16	4506	14.9	0	13.2	89.5
4/8/16	4529.88	19.7	0	19	140.1	5/5/16	4585.83	15.1	0.7	16.5	112.6
4/9/16	4475.08	18.4	0	23	189.5	5/6/16	4326.71	16.4	0	15.3	116.8
4/10/16	4080.04	17.1	0	19.5	205.2	5/7/16	4122.79	17.8	0	13.4	107.3
4/11/16	4465.13	15.8	0	11.8	106	5/8/16	3936.46	19	0	15.9	104.5
4/12/16	4441.13	18.3	0	11.8	108.9	5/9/16	4355.58	19.2	0	12.9	116
4/13/16	4507.46	19.1	0	12.6	93.1	5/10/16	4524.04	20.1	0	13.2	122.2
4/14/16	4615.54	19.8	0	12.1	88.9	5/11/16	4698.29	20.3	0	12.7	93.7
4/15/16	4399.79	20.8	0	11.5	96.9	5/12/16	4877.67	22	0	12.4	79.5
4/16/16	4251.46	19.7	0	14.2	104.2	5/13/16	4558.38	23.9	0	21.3	212.1
4/17/16	3928.63	20.6	0	11.2	76.9	5/14/16	4394.08	21.2	0	16.4	183
4/18/16	4449.96	21.7	0	12	69.9	5/15/16	4116.83	21.4	0	17.8	147.8
4/19/16	4688.79	22.6	0	12.7	89.3	5/16/16	4479.29	21.4	0	25.3	208.9
4/20/16	4550.29	21.5	0	15.8	127.2	5/17/16	4614.42	20.1	0	13.5	111.8
4/21/16	4563.42	15.8	0	33.3	348.5	5/18/16	4609.46	18.7	0	12.2	96.9
4/22/16	4613.75	17	0	17.7	147	5/19/16	4724.13	18.8	0	16.2	137.7

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
5/20/16	4919.46	19.1	0.3	14.9	96.9	6/16/16	5374.54	27.1	0	13.1	106.8
5/21/16	4756.67	18.9	2.4	16.5	147.4	6/17/16	5723.79	30	0	8.7	81.1
5/22/16	4084.17	17.4	0	18.4	197	6/18/16	5811.29	32.5	0	8.9	97.2
5/23/16	4237.33	20.4	0	14.3	112.7	6/19/16	5656.75	32.9	0	15.6	116

5/24/16	4427.29	21.3	0	18.4	186.1	6/20/16	5863.71	32.1	0	12.8	105.8
5/25/16	4353.88	21.2	0	25.8	212.8	6/21/16	6662.46	32	0	18.6	132.1
5/26/16	4449.33	22.5	0	15.4	142.4	6/22/16	6782.17	31.7	0	21.7	266.7
5/27/16	4510.88	23.8	0	13.1	129.8	6/23/16	6915.46	31.1	0	30.1	320.7
5/28/16	4380.54	23	0	13.5	134.5	6/24/16	6952	31.2	0	30.1	352.6
5/29/16	4192.71	22.8	0	17.4	110	6/25/16	6296.88	29.7	0	30.2	298.3
5/30/16	4768.5	24	0	13.9	104.9	6/26/16	5499.38	27.8	0	16.9	169.2
5/31/16	4914.96	25.6	0	17.6	107.6	6/27/16	6363.88	28.1	0	15.3	115
6/1/16	5104.21	27	0	14.3	120.8	6/28/16	6345.92	27	21.2	23.7	122.4
6/2/16	5069.71	26.4	0	15.3	111	6/29/16	5892.21	26	0	15.6	139.2
6/3/16	5005.38	25.3	0	18.5	121.4	6/30/16	6196.33	26.6	0	16	110
6/4/16	4714.25	24.3	0	13.7	96	7/1/16	6331.79	27.8	0	15.5	123.8
6/5/16	4393.63	24.5	0	14.8	99.9	7/2/16	5952.5	28.7	0	17.1	141.8
6/6/16	4896.33	24.7	0	13	96.2	7/3/16	5435.75	28.9	0	15.5	105.3
6/7/16	5025.71	22.2	14.6	21	107.8	7/4/16	6366.29	28.6	0	21	209.5
6/8/16	4756.38	20.7	0	22.1	236.4	7/5/16	6553.54	28.2	0	21.9	286.6
6/9/16	4689.04	20.1	0	13.8	110.8	7/6/16	6400	27.6	0	20.7	251.8
6/10/16	4838.58	20.8	0	17.3	123.7	7/7/16	6221.17	27.6	0	18.5	164.1
6/11/16	4603.25	22.8	0	13.8	111	7/8/16	6056.88	26.9	0	19.7	242.2
6/12/16	4349.54	24.1	0	20.5	141.5	7/9/16	5708.29	27.1	0	19.9	190.2
6/13/16	5019.46	23.3	0	16.6	141.7	7/10/16	5472.21	28.1	0	16.6	170.3
6/14/16	4934.83	24.6	1	23.5	164.7	7/11/16	6210.67	27.8	0	25.5	308.9
6/15/16	4976.79	25	0	31.7	234.4	7/12/16	6386.13	27.8	0	16.2	195.5

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
7/13/16	6546	27.6	0	14.6	109.8	8/9/16	5984.04	28.2	0	26.9	274
7/14/16	6863.92	28.8	0	13.6	115.6	8/10/16	5953.21	29.7	0	14.3	158.2
7/15/16	6988.13	30.5	0	14.4	111.4	8/11/16	6175.04	29.7	0	13	110.1
7/16/16	6081.58	28.5	0	25.2	230.8	8/12/16	5854.88	28.9	0	17.7	141.5
7/17/16	5382.04	27	0	18.4	146.1	8/13/16	5055.54	24.1	0	33.4	395.9
7/18/16	5874.08	26.9	0	32	243.6	8/14/16	4443.17	23.6	0	28.6	303.7
7/19/16	6097.42	25.9	0	22.6	282.3	8/15/16	4208.38	25.4	0	22.4	251
7/20/16	6033.92	26.1	0	27	293.7	8/16/16	5095.25	28.4	0	15	142.7
7/21/16	6088.75	26.5	0	15	172.8	8/17/16	5534.88	28	0	16.8	147.5
7/22/16	6275.92	27.4	0	16	130	8/18/16	5701.21	28.7	0	12.5	94.5
7/23/16	6040.71	28.4	0	16.4	148.3	8/19/16	5726.08	28.5	0	19.3	166.6
7/24/16	5768.25	29.8	0	22	226.3	8/20/16	5468.54	28.2	0	19.2	164.6
7/25/16	6573.42	29.9	0	22.9	270.3	8/21/16	5168.54	28.9	0	14	162.1
7/28/06	6574.04	29	0	16.4	169.2	8/22/16	5969.21	28.8	0	12.1	96
7/27/16	6440.25	28.6	0	16.2	180.6	8/23/16	5860.54	27.8	0	21.2	184.8
7/28/16	6556.96	29.5	0	15.5	186	8/24/16	5610.58	27.4	0	31.1	331
7/29/16	6631.79	29.5	0	17	154.8	8/25/16	5694.21	26	0	39.8	616.8
7/30/16	6340.5	30.5	0	16.3	160.4	8/26/16	5362.13	25.5	0	39.1	563.4
7/31/16	5935.33	30.4	0	22.6	229.8	8/27/16	5034.58	25.2	0	25.4	356.6
8/1/16	6760.13	30.9	0	17.6	167	8/28/16	4726.25	25.6	0	15.2	213.2
8/2/16	6812.83	30.5	0	13	97.4	8/29/16	5474.42	26.5	0	13.6	111.7
8/3/16	6711.63	29.4	0	20.7	181.1	8/30/16	5779.63	26.8	0	13	81.7
8/4/16	6670.83	29.1	0	21.2	227	8/31/16	5882.54	27.7	0	16.3	149.1

8/5/16	6622.83	30	0	19.6	241	9/1/16	5810.42	27.3	0	21.3	271
8/6/16	6219.42	30.4	0	16.5	156.1	9/2/16	5577.46	24.9	0	19.4	175.4
8/7/16	5725.71	29.1	0	25.2	233	9/3/16	4937.54	25.1	0	21.9	248
8/8/16	6243.54	29.6	0	21.2	189.2	9/4/16	4575.58	25.6	0	20.7	239

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
9/5/16	5228	24.9	0	16.8	126.7	10/2/16	4277.5	21.8	0	10.7	64.6
9/6/16	5558.21	23.9	0.7	15.2	105.5	10/3/16	4759.42	23.8	0	9.9	81.2
9/7/16	5265.17	23.7	1.4	15.6	97.7	10/4/16	4897.5	24.3	0	16.2	123.1
9/8/16	5357.08	24.7	0	19.5	187.6	10/5/16	4757.17	22	0	13.7	142.7
9/9/16	5205.67	25.7	0	16.1	145	10/6/16	4838.13	20.9	0	14	135.4
9/10/16	4893.29	24.2	9.4	10.9	51.5	10/7/16	4911.96	20	8.4	31	136
9/11/16	4486.79	23.3	9	10.9	56.1	10/8/16	4435.75	21	0.3	22.8	181.6
9/12/16	4965.08	23.9	0	16.2	114	10/9/16	4176.92	20.5	0	13.3	110.6
9/13/16	5012.67	24.9	0	17.3	140.6	10/10/16	4931.13	19.7	0.3	13.8	82.9
9/14/16	4997.17	24.5	0	13.2	90.8	10/11/16	5063.54	19.5	5.6	16.7	77
9/15/16	5098.38	25	0	10.1	81.7	10/12/16	4812.54	21.1	0	25.2	170.7
9/16/16	5114.38	24.9	0	14.5	106.3	10/13/16	4586.21	18.6	0	13.5	97.9
9/17/16	4901.88	25.4	0	12.5	113.7	10/14/16	4612.54	18.3	0	12.8	127.2
9/18/16	4713.88	27	0	17	134.1	10/15/16	4597.63	18	0	18.9	219.6
9/19/16	5275.92	25.3	0.3	18.3	150	10/16/16	4386.29	18.9	0	18.6	117.9
9/20/16	4925.71	23.8	0	20.9	183.9	10/17/16	4822.08	17.4	0.3	25.8	233.7
9/21/16	4988.75	21.9	0	16.8	99.7	10/18/16	4903.25	14.5	0.3	21.5	285.7
9/22/16	4986.25	20.1	0	17.6	103	10/19/16	4975.58	14.7	0	14.3	111.8
9/23/16	4603.58	20.2	0	20.6	210.8	10/20/16	5054.46	15.9	0	18.3	240.4
9/24/16	4443.75	19.1	0	22.7	253	10/21/16	5188.46	17.1	0	17.2	100.2
9/25/16	4112.08	19.1	0	20.9	201.6	10/22/16	5072.04	17.2	11.1	12.9	57.6
9/26/16	4637.79	18.5	0	21.6	172.3	10/23/16	4315.67	18.2	0	10.4	110.9
9/27/16	4777.88	18.7	0	17.9	186.1	10/24/16	4685.96	18.7	0	18.1	133.7
9/28/16	4691.25	19.3	0	22.2	254	10/25/16	4772.17	17.5	0	16	166.5
9/29/16	4622.67	19.8	0	13.8	115.4	10/26/16	4787.08	17.2	0	15.1	108.9
9/30/16	4667.54	20.7	0	12	86	10/27/16	5081.42	16.1	0	27.7	293.5
10/1/16	4503.75	21.4	0	10.3	82.5	10/28/16	4601.13	13.8	0	30.9	477.6

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
10/29/16	4664.63	14	0	24.5	253.2	11/25/16	5782.21	12.4	0	8.9	63.5
10/30/16	4501.33	15.1	0	8.4	74.9	11/26/16	5642.38	14.3	3.5	5.6	42.9
10/31/16	5070.79	13.2	0	18.6	191.7	11/27/16	5314.29	14.6	58.5	8.3	40.2
11/1/16	5022.38	12.3	0	18.2	137.5	11/28/16	5675.29	13.8	20.9	11.6	58.9
11/2/16	5057	12.6	0	12.5	100.3	11/29/16	6224.75	10	2.7	22.2	174.9
11/3/16	5029.13	15.3	0	11.9	100.3	11/30/16	6332.63	6.1	3.4	43.7	474.3
11/4/16	5106.42	16.1	0	8.2	66.5	12/1/16	6290.21	5.8	0	27.8	186.9
11/5/16	4740.38	16.8	0	11.1	80	12/2/16	6045.79	9.5	0	22.9	216.8
11/6/16	4455.25	17	0	11.9	87.8	12/3/16	5888.71	11.6	1.7	12.3	148.6
11/7/16	4921.46	18.7	0	16.3	145.8	12/4/16	5666.5	11.4	0.3	19.4	286.2
11/8/16	5004.58	20.9	0	12.3	84.1	12/5/16	6014.04	9.8	0	24.8	299



11/9/16	5121.71	18	7	33.4	230.8	12/6/16	6177.75	8.3	0.3	9.4	68.1
11/10/16	4912.17	15.7	0	18.5	152.6	12/7/16	6152.58	10.4	0.3	22.9	135.9
11/11/16	4790.79	16	0	16.8	104.8	12/8/16	6055.21	7.2	0	21.9	220.9
11/12/16	4929.96	16.1	0	19.2	158.9	12/9/16	6037.42	6.5	0	6.4	74.1
11/13/16	4367.88	15.6	0	19.5	178.3	12/10/16	5715.71	10.3	0	8.1	85.6
11/14/16	4993.96	12.8	0	11.8	99	12/11/16	5350.46	10.7	0	9.8	87.5
11/15/16	5647.04	11.3	0	20.6	285.6	12/12/16	5833.17	12.8	0	15.8	143.2
11/16/16	5580.17	10	0	17	185.8	12/13/16	6112.04	9.2	1	30.9	320
11/17/16	5493.08	9.7	0	12.8	143.9	12/14/16	6453.21	4.2	0	20.7	182
11/18/16	5434.5	11.2	0	14.1	152.9	12/15/16	6576.46	7	0	14.5	91.3
11/19/16	5301.21	12.1	0	11.9	118	12/16/16	6757.63	6.2	0	21.7	318
11/20/16	4899.79	12.2	0	10.5	84	12/17/16	6447.33	4.8	0	24.5	289
11/21/16	5404.08	11.8	0	17.9	120.4	12/18/16	6077.71	4.8	0	8	88.8
11/22/16	5630.67	11.9	0	23.3	222.3	12/19/16	6600.92	5.3	0	8	71.3
11/23/16	5687.42	11.4	0	18.9	133.3	12/20/16	6762.25	5.9	0	10.9	76.9
11/24/16	5653.63	11.2	0	8.1	86.9	12/21/16	6741.63	6	1	31.8	392.1

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
12/22/16	6741.25	5.2	0.3	21.3	287.8	1/18/17	6862.75	9.4	10.6	11.7	98.4
12/23/16	6555.58	6.5	0.3	24	303.6	1/19/17	6652.38	9.6	0.7	25.8	156.8
12/24/16	5834.92	8.3	0	19.9	222.8	1/20/17	6606.17	6.4	0.3	19.7	244.7
12/25/16	5328.21	8.3	0	26.7	140.5	1/21/17	6200.96	6.5	0.3	11.3	104.2
12/26/16	5129.71	9.9	0	16.6	151.7	1/22/17	5906.08	5.4	0	22.4	159.6
12/27/16	5808.88	10.5	0	8.5	74.7	1/23/17	6866.04	6	0	20.8	280.4
12/28/16	6170.88	5.9	8.5	39.1	320.7	1/24/17	7195.96	7.3	7.9	17.8	242.5
12/29/16	6595.75	2.5	22.7	39.2	462.7	1/25/17	7045.96	6.3	1.3	12.7	113.1
12/30/16	6619.04	1.8	3.1	24.5	183.5	1/26/17	7218.46	4	0	18.7	300.4
12/31/16	6821.17	2.7	0	21.5	196.9	1/27/17	6970.21	2.8	0	16.2	175.3
1/1/17	5575.5	4.2	0	12.6	77.8	1/28/17	6452	4.5	0	12.2	122.4
1/2/17	5942.79	5.8	0	14	101.1	1/29/17	6320.75	5.6	0	17.1	202.5
1/3/17	6270.5	8.2	0	16.7	110.4	1/30/17	6951.58	5.1	0	14.4	116.5
1/4/17	6365.08	9.3	0	11.6	86.2	1/31/17	7051.38	4.5	0	13.4	125.4
1/5/17	6333.38	11.4	0	22.5	170	2/1/17	6681.17	5.8	0	7.6	81.6
1/6/17	5857.08	9.4	0.3	31.4	254.6	2/2/17	6458.83	8.9	0	11.2	87.8
1/7/17	6779.04	1	0	28.3	343.2	2/3/17	6119.5	10.5	0	12.3	82.8
1/8/17	6614	-1.2	0	21.5	212.4	2/4/17	5645.04	11.5	0	19.8	162.4
1/9/17	7647.63	-1.1	1.4	16.1	145.2	2/5/17	5238.17	12.7	0	9.1	78.8
1/10/17	7595.5	0.7	1	26.8	119.2	2/6/17	5625.58	13.1	0	20	183.5
1/11/17	7503.38	5.7	11.5	15.5	107.1	2/7/17	6091.46	10.9	9.6	22.9	154.8
1/12/17	6890.75	8.2	0.3	16.8	196.8	2/8/17	5940.38	10	3	13.3	82.8
1/13/17	6881.71	6.7	0	16.8	111.4	2/9/17	6126.04	8.7	0	24.8	301.5
1/14/17	6470.58	9.8	0	14.9	123.4	2/10/17	6317.67	7.9	0	28.1	439.8
1/15/17	5884	8.9	4	15.9	170.2	2/11/17	5940.92	7	0	26.9	348.8
1/16/17	6741.63	8.6	6.3	15.8	128.1	2/12/17	5845.63	5.3	0	16.3	178.3
1/17/17	6840.29	8.9	1.7	15.9	77.7	2/13/17	6657.75	4.4	0	20.2	231.2

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
2/14/17	6468	5	0	20.3	227.9	3/12/17	4994.13	11	0	19.9	177.1
2/15/17	6161.42	6.9	0	14.6	75.6	3/13/17	5282.79	11.8	0	20.6	89.8
2/16/17	6102.04	7.5	0	20.7	196.2	3/14/17	5594.46	10.4	0	11.5	91.9
2/17/17	6088.71	7.7	0	11.7	111.1	3/15/17	5673.25	9.9	0	11.8	75.8
2/18/17	5674.88	10.1	0	15.7	111	3/16/17	5697.92	9.6	0	17.5	106.6
2/19/17	5603.13	11.6	0	17.9	135.3	3/17/17	5317.54	10.4	0	23.7	178.3
2/20/17	5582.04	12.6	0	13.9	110.6	3/18/17	5042.42	11	0	16.2	138
2/21/17	5683.88	10.9	0	13	126	3/19/17	4608.67	13.4	0	20.7	119.8
2/22/17	5377.83	11.3	0	11.6	92.7	3/20/17	4770.54	16.1	0	9.9	70.8
2/23/17	5293.96	12.1	0	17	127.5	3/21/17	4815.58	15.9	0	13.5	86.7
2/24/17	5193.25	12.7	0	23.3	156.8	3/22/17	4819.29	15.5	0	16.4	141.5
2/25/17	5218.17	13.4	1	13	100.9	3/23/17	4634.63	16.2	0	12.8	99.7
2/26/17	5095.21	13.3	4.5	13.1	118.4	3/24/17	4558.08	16.2	0	10.1	77.4
2/27/17	4689.42	12.7	0	11.2	116.3	3/25/17	3958.67	16.8	0	11.9	86
2/28/17	5125.04	12.8	0	10.2	78.8	3/26/17	4038.54	16.9	0	23.5	149.6
3/1/17	5272.79	13.8	0	20.7	140.7	3/27/17	4914.79	11.9	0	34.8	403.7
3/2/17	5080.46	12.8	0	19.8	194.2	3/28/17	4836.25	10.8	0	17.3	74.7
3/3/17	4995.13	12.2	0	8.8	73.1	3/29/17	4791.33	13.4	0	14.7	24.7
3/4/17	4793.88	12.6	0	15.5	145.7	3/30/17	4857.04	15.3	0	14.5	48.6
3/5/17	4545.08	13	0	11.6	81.3	3/31/17	4728.79	15.6	0	26.5	236.9
3/6/17	5114.92	13.8	0	14.9	108.6	4/1/17	4421.33	14.6	0	14.3	124.4
3/7/17	5395.92	12.5	0.3	13.2	114.7	4/2/17	4108.67	13.7	0	13.5	68
3/8/17	5609.92	11.1	7.7	13.5	164.5	4/3/17	4967.79	13.4	0	10.3	48.3
3/9/17	5855.13	10.5	25.8	22.6	193.5	4/4/17	4894.71	16	0	9.6	68.6
3/10/17	5793.58	11.1	3.9	19.3	126.4	4/5/17	5013.33	15.3	0	15.6	75.3
3/11/17	5884.25	9.6	23.2	29.8	280.2	4/6/17	4771.63	15.1	0	12.1	57.9

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
4/7/17	4947.92	14.2	0	9.5	53.8	5/3/17	4742.58	21.4	0	10.6	63.9
4/8/17	4522.08	13.7	0	13.5	115.8	5/4/17	4797.54	21.3	0	11	75.5
4/9/17	4197.79	14.1	0	14	119.9	5/5/17	4744.42	22.5	0	21.1	107.1
4/10/17	4624.25	13.4	0	14.6	135.3	5/6/17	4538.29	22	0	19.6	142.5
4/11/17	4621.75	14.5	0	16.9	129.3	5/7/17	4205.63	21.5	0	19.3	151.9
4/12/17	4692.38	15.2	0	13.9	93.1	5/8/17	4608.17	20.9	0	10.7	82
4/13/17	4442.54	17.3	0	14.5	80.6	5/9/17	4723.04	20.3	0	22	164.1
4/14/17	3815.17	17.8	0	9.5	60.4	5/10/17	4752.67	19.7	0	12.8	70.1
4/15/17	4086.96	18.2	0	14	88.1	5/11/17	4864.29	20	0	12	95.3
4/16/17	3373.58	17.5	0	14.8	90.7	5/12/17	4944.29	20.7	0	9	56.8
4/17/17	3845.75	15.4	8.1	25.8	83.5	5/13/17	4777.42	25.1	0	9.2	57.9
4/18/17	4261.96	14.4	0	11.3	82.4	5/14/17	4276.33	26.3	0	17.8	88.3
4/19/17	4650.54	16.5	0	15.8	144.9	5/15/17	4720.54	23	0	20.9	223.4
4/20/17	4562.58	16.9	0	18	153.6	5/16/17	4992.04	20	0	22	272.2
4/21/17	4775.71	12.4	0	17.2	127.2	5/17/17	4711.42	16.6	6.5	28.8	219.6
4/22/17	4838.17	11.4	0	22.2	148	5/18/17	4753.17	15.5	14.8	15.5	165.8

4/23/17	4257.67	13.4	0	17	119.6	5/19/17	4456.13	18.2	0	21.3	204.7
4/24/17	4589.63	14.8	0	16	113.2	5/20/17	4358.25	18.8	0	15.9	107.6
4/25/17	4756.58	15.7	0	13.9	72	5/21/17	4145.04	19.9	5.8	14.6	100.4
4/26/17	4688.79	17	0	11.5	73.5	5/22/17	4363.75	19.5	5.2	16	114.6
4/27/17	4710.08	18.8	0	12.3	66.5	5/23/17	4637.67	21	0	12.8	88.7
4/28/17	4667.42	20.1	0	11.9	75.3	5/24/17	4722.29	20.5	0.6	11.2	40.5
4/29/17	4738.88	21.4	0	10.6	63.5	5/25/17	4713.88	19.9	0	16.3	66.8
4/30/17	4269.75	21.5	0	20.2	165.1	5/26/17	4715.75	19.3	1.6	12.5	77.9
5/1/17	3753.75	21.8	0	16.8	106	5/27/17	4525.33	18.9	0	12.1	58.7
5/2/17	4461.08	21.3	0	16.4	124.1	5/28/17	4343.63	16.4	13.9	19.5	114.9

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
5/29/17	4446.5	19.4	0	22.6	246.7	6/24/17	5595.88	28.9	0	9.6	34
5/30/17	4529.5	20.9	0	13	73.6	6/25/17	5399.33	29.4	0	10.8	77.1
5/31/17	4551.46	21.9	0	12.5	91.5	6/26/17	6260.88	29.3	0	10.7	60.9
6/1/17	4722.71	24.1	0	13.4	70.1	6/27/17	6532.5	29.2	0	12.2	67.7
6/2/17	4820.83	25.8	0	11.3	68.6	6/28/17	6756.21	29.9	0	11.7	69.3
6/3/17	4666.5	24.9	0	10.5	61.5	6/29/17	7005.79	31.2	0	10.6	60.4
6/4/17	4206.17	22.9	39	12.8	93.8	6/30/17	7270.71	33.9	0	10.9	47.3
6/5/17	4343.17	23.2	0	10.9	57.3	7/1/17	7148.54	35.4	0	11.3	50.1
6/6/17	4893.08	23.4	0	13.8	86.5	7/2/17	6794.71	35.9	0	16.4	84.9
6/7/17	5098.42	24.1	0	12	61.3	7/3/17	6648.79	31	0	19.2	121.4
6/8/17	5172.88	22.9	1.8	9.6	31.7	7/4/17	6206.42	25.2	0	33.3	327.6
6/9/17	4892.13	23.7	0.3	10.1	67.9	7/5/17	6033.83	25.1	0	20.9	191.3
6/10/17	4709.33	23.6	0	9.9	53.1	7/6/17	6099.29	26.9	0	14.5	136.1
6/11/17	4475.83	20	4.6	22.7	124.4	7/7/17	6347.04	27.8	0	15.8	150
6/12/17	4498.54	22.1	0.3	26.1	186	7/8/17	6101.21	28.4	0	15.5	140.1
6/13/17	4858.42	24.8	0	10.6	76.9	7/9/17	5867.83	29.6	0	14.9	105.6
6/14/17	5130.13	26.4	0	11.5	72.6	7/10/17	6882.67	29.7	0	19.1	189.3
6/15/17	5336.13	26.6	0.3	11.6	86.2	7/11/17	7115	30.5	0	18.2	120.6
6/16/17	5412.17	24.4	3.4	13.1	94.8	7/12/17	7351.83	30.8	0	11.8	57.2
6/17/17	4961.29	23.4	2.8	9.6	41	7/13/17	7513.54	31.7	0	18.3	127.9
6/18/17	4337.17	18.8	8.3	8.6	37.2	7/14/17	7206.92	30.2	0	24.6	282.8
6/19/17	4699.54	20.6	0.3	15.3	97.5	7/15/17	6233	27.7	0	19.9	249.2
6/20/17	4969.5	23.3	0	15.4	86.4	7/16/17	5356.21	25.8	0	21.1	216.3
6/21/17	5144.04	24.7	0	10.2	45.6	7/17/17	5103.63	22.3	2.8	15.7	93.7
6/22/17	5418.29	26.2	0	9.7	49.7	7/18/17	5011	22.8	0	24.2	157.4
6/23/17	5610.5	27.9	0	10	54	7/19/17	4966.54	25.3	0	16.6	165.6

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
7/20/17	5205.13	26.8	0	18.4	191.8	8/15/17	4875.54	27.5	0	15.9	123
7/21/17	5413.17	27.8	0	18.8	179.1	8/16/17	5655.17	28.4	0	19.6	167.5
7/22/17	5367.42	29	0	18.5	195.5	8/17/17	5843.29	28.7	0	23.5	250.8
7/23/17	5338.92	30.7	0	14.7	82.7	8/18/17	5879.25	29.4	0	25.1	252.1
7/24/17	6472.63	31	0	13.7	82.5	8/19/17	5698.33	29.8	0	23.7	267.5
7/25/17	6762.33	30.8	0	11.5	87.1	8/20/17	5364.54	29.5	0	13.3	115.2

7/26/17	6574.13	29.5	0	19.5	107.7	8/21/17	5838.63	26.3	0	16.1	77
7/27/17	6031.5	26.7	0	18.5	105.3	8/22/17	5519.33	24.5	0	13.4	80.3
7/28/17	5717.92	26.2	0	9.6	53.4	8/23/17	5375.21	24	0	14.7	114.1
7/29/17	5713.58	27.6	0	16.9	73.9	8/24/17	5399.71	24.3	0	17	135.2
7/30/17	5410.17	28.2	0	16	153.5	8/25/17	5264.83	25.8	0	25.7	267.9
7/31/17	6090.79	28.1	0	19.1	209	8/26/17	4950.67	26.3	0	21.8	216.7
8/1/17	6114.75	27.7	0	14.7	169.3	8/27/17	4568.38	26.2	0	15.5	162.7
8/2/17	6149.71	27.8	0	18	177.7	8/28/17	5390.04	27.2	0	20.3	172.3
8/3/17	6449.71	30.1	0	24.5	184.9	8/29/17	5730.88	28.2	0	24.8	256.1
8/4/17	6652.5	31	0	21.6	183.8	8/30/17	5204.79	23.1	0	24.9	336.6
8/5/17	6536.5	31.3	0	17.9	154.2	8/31/17	5073.17	23.3	0	19	152.2
8/6/17	6271.71	32.5	0	18.3	132	9/1/17	5177.58	24	0	11.9	71.8
8/7/17	7174.83	32.6	0	16.6	126.3	9/2/17	5072.17	26	0	10.6	61.1
8/8/17	7282.29	32.2	0	19.1	177.6	9/3/17	4834.25	27.1	0	15.5	90.9
8/9/17	7052.17	31.6	0	22.3	180.2	9/4/17	5266.58	26.9	0	13.9	110.4
8/10/17	6987.38	31.6	0	24.5	237.4	9/5/17	5385.21	24.2	0	16.6	120.8
8/11/17	6938.13	31.4	0	16.4	140.3	9/6/17	5062.38	23.2	0.9	16.1	108.1
8/12/17	6417	31.2	0	15.3	81.3	9/7/17	5135.29	23.8	0	12.4	77.8
8/13/17	5353.08	29.3	0	25.4	132	9/8/17	5238.04	24.6	0	12.6	70
8/14/17	5405.33	27.7	0	12	68.4	9/9/17	5137.83	25.3	0	12.7	75.7

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
9/10/17	4681.46	25.4	0	13	75.9	10/6/17	4733.25	20.7	0	12.9	72.8
9/11/17	5301.63	25.7	0	13.2	84.2	10/7/17	4754	21	0.6	20.7	136.6
9/12/17	5394	26.2	0	25.6	242.3	10/8/17	4050.83	16.6	0.3	23.5	190.8
9/13/17	5399.08	26.2	0	11.8	69.1	10/9/17	4507	16.9	0	10.1	57.8
9/14/17	5404.58	26.8	0	13.5	63.4	10/10/17	4673.58	17.3	0	9.2	45.4
9/15/17	5444.21	26	0	11.9	55.2	10/11/17	4838.04	17.7	0	14.7	116.8
9/16/17	5179.17	26.1	0	8.2	32.5	10/12/17	4726.92	18.1	0	10.2	56.4
9/17/17	4852.29	26.8	0	9.8	52	10/13/17	4659.29	18.9	0	14.7	65.7
9/18/17	5572.5	28.5	0	10.8	54.5	10/14/17	4461.71	19.8	0	20.6	181.9
9/19/17	5731.96	27.4	0	13.5	58.6	10/15/17	4139.96	19.2	0	22.1	202.2
9/20/17	5550.58	26.4	0	15.5	129.5	10/16/17	4587.38	20.4	0	16.2	123.7
9/21/17	5099.08	23.2	0	24.9	240.3	10/17/17	4739	20.8	0	22.1	151.7
9/22/17	4833	21.4	0	14.8	117.5	10/18/17	4768.75	19.6	0	10.7	62.4
9/23/17	4577.04	20.4	0	11.5	67.7	10/19/17	4796.67	19.2	0	7.1	38.1
9/24/17	4231.54	20.5	0	14	124.6	10/20/17	4728.29	19.7	0	7.8	41.1
9/25/17	4880.58	21.1	11.1	11.5	69.9	10/21/17	4520.63	19.8	0	8.8	37.2
9/26/17	4890.38	19.6	0.9	12.8	50.7	10/22/17	4145.33	19.7	0	9.8	51.5
9/27/17	4871.63	20.1	4	11.4	71.5	10/23/17	4865.63	18.7	0.3	10.8	62.2
9/28/17	4967.17	19.3	0.3	29	388.6	10/24/17	4757.54	17.2	0	20.8	173.3
9/29/17	4880.79	17.6	0	34.2	408.5	10/25/17	4957.08	15.8	0.6	25.1	227.2
9/30/17	4741.21	17.3	0	22.1	139.9	10/26/17	4740.92	14.8	0	21.1	247.2
10/1/17	4298.25	16.5	0	19.9	121.3	10/27/17	4642	16	0	8.8	49.4
10/2/17	4568.38	17.1	0	18.7	140.6	10/28/17	4574.67	15.2	1.2	24.8	125.9
10/3/17	4660.58	17	0	18.1	106.1	10/29/17	4247.79	15	0	27	228.4
10/4/17	4625.83	17.8	0	10.8	53.9	10/30/17	4822.96	16	0	19.8	117.7
10/5/17	4666.92	19.4	0	10.3	62.3	10/31/17	5114.08	14.3	0	16.7	141

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
11/1/17	5292.63	13.1	0	16.4	170.8	11/27/17	5781.71	12.8	3.7	15.7	100.8
11/2/17	5177.63	11.8	0	11.1	56.8	11/28/17	5910.58	10.3	0.3	12.4	75.5
11/3/17	5264.13	13.5	0	11	51	11/29/17	5878.63	10.7	0	13.9	106.8
11/4/17	5257.92	13.4	2.5	19.9	113.3	11/30/17	5991.75	14.9	0	25.1	234.1
11/5/17	4740.13	13.8	0	19.7	132.3	12/1/17	5630.13	16.9	0	28.3	366.6
11/6/17	5294.46	12.9	0	11	49.6	12/2/17	5415.75	17.6	0	22.3	227.5
11/7/17	5444.04	15.5	0	9.4	44.4	12/3/17	4676.21	17.1	0	18.5	208.5
11/8/17	5592	13.9	2.8	12.8	42.1	12/4/17	5324.83	12.7	0.9	9.9	68.7
11/9/17	5208	14.8	0	5.6	30.3	12/5/17	5585.54	9.4	0	22.9	149.1
11/10/17	5178.96	14.2	0	9.1	56.1	12/6/17	5874.29	6.9	0	28.7	171.4
11/11/17	5155.29	15.9	0	11	53.6	12/7/17	5951.08	11	0	6.1	13.1
11/12/17	4710.54	17	0	13.2	68.1	12/8/17	5878.71	9.7	0	9.7	62.3
11/13/17	5275.79	14.5	13	22.9	65.6	12/9/17	5676.83	11.6	0	24.4	133.1
11/14/17	5329.29	15.5	0.6	7.7	29.3	12/10/17	5147.67	13.1	0	27.8	229.5
11/15/17	5392.92	17.4	0.6	17.3	103.2	12/11/17	5856.42	9.4	0	12.3	62.2
11/16/17	5440.17	15.4	46.3	25.5	160.3	12/12/17	5911.75	11.4	0	10.6	46.2
11/17/17	5507	13.5	21.3	13.7	62.3	12/13/17	5761.71	12.9	0	14.6	74.7
11/18/17	5322.21	13.8	4.2	6.5	15.5	12/14/17	5502.71	14	0	19.4	166
11/19/17	4912.08	12.6	13.6	9.8	14.7	12/15/17	5542.17	12.7	0	19.7	123.4
11/20/17	5435.08	11.8	2.5	33.8	283.8	12/16/17	5658.21	13.8	1.9	23.7	174.8
11/21/17	5558.17	8.6	0	12.8	82.4	12/17/17	5249.71	14.2	1.9	23.9	173.7
11/22/17	5637.46	10.1	0	7.7	31.4	12/18/17	6030.08	10	0	11.5	82.4
11/23/17	5587.21	12	0	6.9	29.5	12/19/17	6231.79	7.3	0	9.1	66.8
11/24/17	5573.42	12.6	0	6	25.9	12/20/17	6544.25	7.1	0	13.8	78.9
11/25/17	5481.58	12.7	0	6	26.6	12/21/17	6947.88	7.1	0	22.1	222.1
11/26/17	4974.04	13.6	0	15.2	69.2	12/22/17	7046.75	5.5	5.9	29.7	335.9

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
12/23/17	6311.58	5.8	0.9	31	303.6	1/18/18	6020.79	8.9	1.9	1.8	6.7
12/24/17	5813.88	6.4	1.2	14.3	114.9	1/19/18	6015.08	8.5	0	17.6	82.6
12/25/17	5126.83	10.1	0	14.6	41.3	1/20/18	5855.17	11.2	0	11.2	67.3
12/26/17	5038.71	9.7	0	9.5	46.9	1/21/18	5545.67	12.2	0.3	11.3	96.4
12/27/17	5712.46	10.2	0	7.9	38.8	1/22/18	5920.42	8.5	5.6	27.1	195.7
12/28/17	5924.83	12.2	2.5	22.4	183.8	1/23/18	6250.17	7	3.1	14	112.1
12/29/17	5626.71	11.1	5.3	17	99.6	1/24/18	6531.54	4.7	0.3	26.8	273.2
12/30/17	5357.83	9.5	0	12.6	72.6	1/25/18	6457.96	4.8	0	15.7	172.5
12/31/17	5395.67	8.4	0	8.4	57.6	1/26/18	6353.17	5.9	0	11.9	85.9
1/1/18	4831.04	9.2	0	11.8	65	1/27/18	6056.75	5.8	0	7.8	59
1/2/18	5265.58	11.1	1.5	15.2	94.2	1/28/18	5492.71	7.4	0	5.5	45.8
1/3/18	5652.88	10	2.5	12.5	58.5	1/29/18	5958.79	8.9	0	5.1	41.1
1/4/18	6253.21	7.8	15.1	17.6	109.3	1/30/18	5992.04	10	0	5.2	42.1
1/5/18	5949.92	9.1	0	0	0	1/31/18	5857.21	10.8	0	6.2	46.3
1/6/18	5310.54	9.8	0	0	0	2/1/18	5895.38	10.6	0	10.3	77.8
1/7/18	5305.96	12.3	0	0	0	2/2/18	6093.08	11.4	0	7.6	58.8

1/8/18	5960.04	13.4	0	2.4	0.6	2/3/18	5709.38	12.6	1.2	15.1	132.4
1/9/18	6108.13	12.4	0	0.4	0.2	2/4/18	5279.04	13.4	0	10.8	83.4
1/10/18	6187.33	10.8	0	0	0	2/5/18	5427.5	10.8	0	14.1	105.4
1/11/18	6152.42	11.6	6.2	0	0	2/6/18	5698	10	0	10.4	103.2
1/12/18	5962.58	11.6	5.9	0	0	2/7/18	5828	12.2	0	13.3	100.4
1/13/18	6020.04	9.8	21.3	0.6	0.3	2/8/18	5429.54	13.7	0	14.2	139.6
1/14/18	5690.42	6.7	3.1	0.7	1.3	2/9/18	5629.17	11.8	0	4.5	30.2
1/15/18	6458.67	7.8	0.3	0	0	2/10/18	5971.38	10.9	15.8	11.6	101.2
1/16/18	6094.67	11.1	0	0.1	0	2/11/18	5289.21	11.9	0	13.1	141.3
1/17/18	5989.21	11.2	0	0.1	0	2/12/18	5626.13	9.9	0	10.4	66.6

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
2/13/18	6006.96	10.7	0	9.4	83.2	3/11/18	4365.5	13.4	0	9.3	61.5
2/14/18	5689.63	10.3	4.6	14.3	140.5	3/12/18	4891.38	14.2	0	10	90.8
2/15/18	6391.58	7.7	25.6	8.4	57.8	3/13/18	4922.92	15.5	0	14.2	161
2/16/18	6060.71	8.6	0.3	14	109	3/14/18	4917.42	14.5	0	12.5	161.4
2/17/18	5417.71	9.5	0	7.4	52.5	3/15/18	4846.46	14.3	0	11.5	103.7
2/18/18	5246.17	9.6	0	9.6	96.3	3/16/18	5219.46	13.4	0	10.4	87.4
2/19/18	5338.88	9.5	0	14.1	131.2	3/17/18	4822.29	16	0	14.2	89.1
2/20/18	6288.13	9	4.9	16.1	215.8	3/18/18	4587.38	17	0.6	10.9	90.3
2/21/18	6196.21	11.3	0	9.5	90.1	3/19/18	5055.5	14	4.9	16.2	121
2/22/18	5950.08	12.3	0	7.7	54	3/20/18	4781.5	13.3	0	18.6	139.4
2/23/18	5786.5	11.6	0	13.8	155.3	3/21/18	5080.63	13.2	0	11.6	82.2
2/24/18	5749.58	11	10.5	14.1	152.2	3/22/18	5469.58	15.4	0	14.5	173.9
2/25/18	5657.71	8.8	0	14.5	149.9	3/23/18	5246.71	13.7	2.5	13.7	141.9
2/26/18	6124.54	10.2	15.8	13.1	107.2	3/24/18	5096.21	11.6	1.5	13.5	112.4
2/27/18	5848.75	11.1	0	16.4	117.3	3/25/18	4987.65	11.7	0.3	12.6	75.5
2/28/18	5756.5	11	4.9	14.6	169.7	3/26/18	5212.71	15.9	0	11.7	123.3
3/1/18	6132.63	8.5	0	9.7	80.6	3/27/18	5150.58	13.8	0	12.4	92.2
3/2/18	6145.54	12.6	0.9	9.2	79.1	3/28/18	5232.54	12.8	2.8	12.6	72.2
3/3/18	5193.38	15.1	0	12.6	88.1	3/29/18	4860.13	13.1	0	12.2	111.6
3/4/18	4613.42	15	0	12	85	3/30/18	4789.75	13.9	0	10.9	76.6
3/5/18	5378.75	15.4	0	16	129.4	3/31/18	4966.71	13.7	0	8.2	51
3/6/18	5255.54	15.8	0	12	111	4/1/18	4246.75	16.5	0	18.1	168.3
3/7/18	4906.17	16.8	0	12.6	119.8	4/2/18	4619	15	0	10.2	91.2
3/8/18	4980.08	14	0.3	19.9	178.3	4/3/18	4678.63	15.2	0	11	71.9
3/9/18	5085.92	12.8	0	7.4	60.2	4/4/18	4640.21	16.2	0	8.6	58.4
3/10/18	4765.29	12.7	0	7.8	69.5	4/5/18	4554.96	17.3	0	8.8	62.9

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)	Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
4/6/18	4083.79	16.4	0	16.8	93.5	5/2/18	4501.42	23	0	11.7	89.5
4/7/18	4462.92	15.7	1.5	22.4	203.6	5/3/18	4898.83	23.1	0	10.8	111.9
4/8/18	3307.96	18.4	0	24.7	191.8	5/4/18	4874.54	23.5	0	10.1	83.1

4/9/18	3340.58	17.5	0	11.4	84.1	5/5/18	4711.96	22	5.9	18.8	96
4/10/18	4173.04	17.1	0	8.4	62.1	5/6/18	4288.63	17.9	23.8	7.7	60.9
4/11/18	4804.04	16.5	0	6.5	40.8	5/7/18	4520.96	17.9	6.8	9.9	67.1
4/12/18	4440.08	18.6	0	10.1	58.5	5/8/18	4665.38	18.5	5.9	8.2	46.4
4/13/18	4392.5	20	0	6.8	54.3	5/9/18	4573.79	20.1	0	10.3	83.5
4/14/18	4261.13	20.9	0	18.5	110.4	5/10/18	4742.38	20	0	17.7	86.8
4/15/18	4164.83	21.3	0	17.1	139.9	5/11/18	4579.96	19.6	0.3	12.3	70.3
4/16/18	4753.88	18.9	0	16.5	148.5	5/12/18	4283.96	20	0	15.1	122
4/17/18	4593.83	17.9	0	10.2	68	5/13/18	4005.46	19.4	0	11	83.6
4/18/18	4627.79	18.5	0	17.1	99.4	5/14/18	4508.79	21.5	0	16.9	113.5
4/19/18	4553.79	20.1	0	18.9	177.4	5/15/18	4774.08	23	0	12.4	101.9
4/20/18	4523.33	18.5	0	28.1	251.9	5/16/18	4877.71	23	0	6.8	54.4
4/21/18	4288.13	16.6	0	18.1	202.1	5/17/18	4816.21	23.1	0	9.7	77.5
4/22/18	3985.08	18.6	0	9.8	71.4	5/18/18	4925.13	23.7	0	11.8	75.2
4/23/18	4391.92	19.5	0	10.5	72.1	5/19/18	4634.42	24.6	0	12.5	112.6
4/24/18	4576.21	20.8	0	8.2	66.8	5/20/18	4321.08	22.3	0	15.9	117.8
4/25/18	4588.58	22.7	0	9.8	71	5/21/18	4590.63	23.3	0	21	225.2
4/26/18	4725.33	22.5	0	8.9	57.3	5/22/18	4734	23.1	0	17.4	140.8
4/27/18	4679.08	23.5	0	13.9	92.6	5/23/18	4870.79	22.5	0	17.1	159.7
4/28/18	4496.25	24.6	0	21.9	282.2	5/24/18	4852.5	20.9	1.9	8.8	44.1
4/29/18	4217.54	22.5	0.3	12	106.5	5/25/18	4782.58	23.5	0	14.6	135.9
4/30/18	4690.21	22.2	0	12.5	104.9	5/26/18	4483.42	23.9	0	21	252
5/1/18	3834.46	23.5	0	14.1	125.3	5/27/18	4101.67	23.4	0	19.5	244.2

Date	Av. D. Load	AV. TEM.	Rain	max Uw (Km/h)	Wind dis (km)
5/28/18	4380.25	23.6	0	18.6	224.5
5/29/18	4875.46	23.7	0	18	187.8
5/30/18	4796	24.2	0	15.5	157.2
5/31/18	4941.92	24.2	0	15.6	184.9
6/1/18	5076.25	25.8	0	14.8	144.2
6/2/18	4985.25	27.1	0	21.2	219.7
6/3/18	4638.63	25.3	0	10.3	81.6
6/4/18	5296	26	0	11.7	92.2
6/5/18	5616.21	27.3	0	12.4	93.8
6/6/18	5744.58	27.8	0	13.9	100.8
6/7/18	5915.46	27	0	10.4	84.7
6/8/18	5930.54	27.2	0	11.4	95
6/9/18	5598.54	27.7	0	14.7	136
6/10/18	5068.79	25.3	12.1	9.6	78
6/11/18	5474.96	26	0	13.7	125.5
6/12/18	5835.96	27.7	0	15.8	155
6/13/18	6006.29	27.4	0	13.1	76.5
6/14/18	5967.04	28	0	12.2	108.7
6/15/18	5659.96	25.6	0	15.8	130.3
6/16/18	5102.21	21.3	34.9	15.9	89.6
6/17/18	4539.25	20.7	3.7	7.3	35.2
6/18/18	5114.79	21.6	2.8	11.8	53.6
6/19/18	5240.71	23.8	0	15.6	132.8

6/20/18	5306.38	26.2	0	16.6	190.2
6/21/18	5578.58	26.2	0	9.6	82.4
6/22/18	5622.04	25.6	0	13.2	103.3