



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ
ΔΙΑΤΑΞΕΩΝ
ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Ανάπτυξη μεθοδολογίας για την βελτίωση της στελέχωσης τηλεφωνικών κέντρων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΕΥΑΓΓΕΛΟΣ ΛΙΕΠΟΥΡΗΣ

Επιβλέπων: Βασίλειος Ασημακόπουλος
Καθηγητής ΕΜΠ
Υπεύθυνος: Ευάγγελος Σπηλιώτης
Δρ. ΗΜΜΥ ΕΜΠ

Αθήνα, Ιούλιος 2019



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ
ΔΙΑΤΑΞΕΩΝ
ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Ανάπτυξη μεθοδολογίας για την βελτίωση της στελέχωσης τηλεφωνικών κέντρων

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΕΥΑΓΓΕΛΟΣ ΛΙΕΠΟΥΡΗΣ**

Επιβλέπων: Βασίλειος Ασημακόπουλος
Καθηγητής ΕΜΠ
Υπεύθυνος: Ευάγγελος Σπηλιώτης
Δρ. ΗΜΜΥ ΕΜΠ

Εγκρίθηκε από τριμελή εξεταστική επιτροπή στις 12 Ιουλίου 2019

Βασίλειος Ασημακόπουλος

Ιωάννης Ψαρράς

Δημήτριος Ασκούνης

Αθήνα, Ιούλιος 2019

Ευάγγελος Σ. Λιέπουρης

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright © Ευάγγελος Σ. Λιέπουρης, 2019

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευτεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Πρόλογος

Η διπλωματική εργασία εκπονήθηκε στα πλαίσια ερευνητικών δραστηριοτήτων της Μονάδας Προβλέψεων και Στρατηγικής. Η μονάδα υπάγεται στον Τομέα Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσεων της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου.

Αρχικά θα ήθελα να ευχαριστήσω τον καθηγητή κ. Βασίλειο Ασημακόπουλο για την ευκαιρία που μου έδωσε να ασχοληθώ με την πρόβλεψη κλήσεων και κατανομή εργαζομένων σε τηλεφωνικό κέντρο και να υλοποιήσω εργαλεία για τη διαχείρισή τους. Επίσης, θα ήθελα να ευχαριστήσω τους καθηγητές κ. Ιωάννη Ψαρρά και κ. Δημήτρη Ασκούνη για τη συμμετοχή τους στην επιτροπή εξέτασης της εργασίας.

Ιδιαίτερα, θα ήθελα να ευχαριστήσω τον κ. Ευάγγελο Σπηλιώτη για τη συνεργασία και τις πολύτιμες συμβουλές του κατά τη διάρκεια εκπόνησης της εργασίας. Τέλος σημαντική συνεισφορά ήταν από την οικογένεια και τους φίλους μου που χωρίς την εμπύχωση και την έμπρακτη στήριξή τους δεν θα είχε ολοκληρωθεί η εργασία.

Ευάγγελος Λιέπουρης

Αθήνα, Ιούλιος 2019

Περίληψη

Η παρούσα διπλωματική εργασία στοχεύει στην έρευνα των μεθόδων πρόβλεψης εισερχόμενων κλήσεων και κατανομής εργαζομένων σε ένα τηλεφωνικό κέντρο, όπως επίσης και στη δημιουργία μεθόδων που βελτιστοποιούν τις υπάρχουσες διαδικασίες. Καθώς η χρήση τηλεφωνικών κέντρων έχει γίνει απαραίτητη για κάθε εταιρία προκειμένου να έχει εύκολη επαφή με τους πελάτες της και το επίπεδο εξυπηρέτησης παίζει καθοριστικό ρόλο στην προτίμηση του καταναλωτή, η διαχείρισή τους γίνεται ολοένα και καθοριστικότερη.

Αρχικά γίνεται μία σύντομη αναφορά στην ιστορία των τηλεφωνικών κέντρων, στην αναγκαιότητά τους καθώς επίσης και στον τρόπο λειτουργίας τους προκειμένου να γίνει κατανοητός ο ρόλος της πρόβλεψης εισερχόμενων κλήσεων και της κατανομής των εργαζομένων σε βάρδιες. Στη συνέχεια, παρατίθενται τα μοντέλα που χρησιμοποιούνται, κυρίως για την πρόβλεψη των εισερχόμενων κλήσεων, με ιδιαίτερη έμφαση στα νευρωνικά δίκτυα. Παράλληλα με τη βιβλιογραφική έρευνα, παρατηρήθηκε η μεθοδολογία που χρησιμοποιείται σε τηλεφωνικό κέντρο τηλεπικοινωνιακού παρόχου. Έχοντας λάβει υπ' όψιν τα παραπάνω, υλοποιήθηκε ένα εργαλείο με τη μέθοδο νευρωνικών δικτύων για την πρόβλεψη των εισερχόμενων κλήσεων και ένα εργαλείο μέσω του Microsoft Excel που κατανέμει τους διαθέσιμους εργαζόμενους σε βάρδιες. Τα διαθέσιμα μοντέλα δοκιμάστηκαν στα ίδια δεδομένα με σκοπό τη σύγκριση των αποτελεσμάτων τους.

Τέλος, παρατίθενται τα συμπεράσματα για την αποδοτικότητα του κάθε μοντέλου και προτείνονται ιδέες για μελλοντική αναβάθμιση των εργαλείων που υλοποιήθηκαν, οι οποίες δεν μπόρεσαν να πραγματοποιηθούν στα πλαίσια αυτής της εργασίας.

Λέξεις κλειδιά:

Τηλεφωνικό κέντρο, πρόβλεψη κλήσεων, νευρωνικά δίκτυα, στελέχωση, κατανομή εργαζομένων

Abstract

This thesis aims at researching the methods of forecasting incoming calls and allocating employees to a call center, as well as creating methods that optimize existing processes. As the use of call centers has become necessary for every company to have easy contact with its customers and the level of service plays a key role in consumer preference, their management is becoming even more significant.

Initially, a brief reference is made to the history of call centers, their necessity and how they work, in order to understand the role of forecasting and planning. The models used are mainly for predicting incoming calls, with special emphasis on artificial neural networks. Along with the literature review, the methodology used in a telecommunication provider's call center was observed. Taking all the above into consideration, an artificial neural network tool for predicting incoming calls and a Microsoft Excel tool, that distributes shifts among employees, was implemented. The available models were tested on the same data to compare their results.

Finally, we draw conclusions about the efficiency of each model and recommend ideas for future upgrading of its tools that could not be achieved in this work.

Key Words:

Call center, call forecast, neural networks, LSTM, call center management, staff scheduling

Περιεχόμενα

Πρόλογος.....	5
Περίληψη.....	7
Abstract	8
1 Ευρεία Περίληψη.....	13
1.1 Η ιστορία των Τηλεφωνικών Κέντρων.....	13
1.2 Αναγκαιότητα Τηλεφωνικών κέντρων.....	14
1.3 Διαχείριση Τηλεφωνικών Κέντρων.....	15
1.4 Εργαλεία Στελέχωσης Τηλεφωνικών Κέντρων	16
1.5 Σκοπός Διπλωματικής Εργασίας.....	17
2 Τεχνικές Προβλέψεων	19
2.1 Μοντέλα Πρόβλεψης	19
2.2 Δείκτες Σφάλματος	23
2.3 Νευρωνικά Δίκτυα.....	26
2.3.1 Ορισμός	26
2.3.2 Ιδιότητες Νευρωνικών Δικτύων	27
2.3.3 Εκπαίδευση Νευρωνικών Δικτύων.....	28
2.3.4 Κατηγορίες Νευρωνικών Δικτύων	30
3 Πραγματική Εφαρμογή σε Τηλεφωνικό Κέντρο.....	37
3.1 Επισκόπηση Εφαρμογής και Διαθέσιμα Δεδομένα.....	37
3.2 Υφιστάμενη Μεθοδολογία Πρόβλεψης και Στελέχωσης	39
3.2.1 Υφιστάμενη Μεθοδολογία Πρόβλεψης Εισερχομένων Κλήσεων	39
3.2.2 Υφιστάμενη Μεθοδολογία Στελέχωσης Προσωπικού	39
4 Προτεινόμενη Μεθοδολογία Πρόβλεψης και Στελέχωσης.....	45
4.1 Προτεινόμενη Μεθοδολογία Πρόβλεψης Εισερχομένων Κλήσεων.....	45
4.2 Προτεινόμενη Μεθοδολογία Στελέχωσης Προσωπικού	51
4.3 Πιλοτική Λειτουργία μέσω Προσομοιώσεων	62
4.3.1 Δεδομένα Προσομοίωσης.....	62
4.3.2 Εφαρμογή και Αποτελέσματα	62
5 Σύγκριση Υφιστάμενης και Προτεινόμενης Μεθοδολογίας.....	73
5.1 Σύγκριση Μεθόδων Πρόβλεψης Εισερχομένων Κλήσεων	73
5.2 Σύγκριση Μεθόδων Στελέχωσης	80
6 Συμπεράσματα και Προοπτικές Βελτίωσης.....	83
Αναφορές	85

Περιεχόμενα Εικόνων

Εικόνα 1 Τρόποι επικοινωνίας συνδρομητών	14
Εικόνα 2 Μοντέλα πρόβλεψης που χρησιμοποιούνται σε τηλεφωνικά κέντρα.....	19
Εικόνα 3 Δομή νευρωνικού δικτύου	26
Εικόνα 4 Δομή feedforward Neural nNetwork.....	30
Εικόνα 5 Δομή Recurrent Neural Network.....	31
Εικόνα 6 Επαναλαμβανόμενη δομή σε απλό RNN.....	33
Εικόνα 7 Επαναλαμβανόμενη δομή σε LSTM	34
Εικόνα 8 Cell state	34
Εικόνα 9 Δομή πύλης.....	34
Εικόνα 10 Forget gate layer	35
Εικόνα 11 Δημιουργία αναβαθμισμένης τιμής στην κυψέλη	35
Εικόνα 12 Εξόδος.....	36
Εικόνα 13 Τρόποι υπολογισμού του wfm (2017).....	38
Εικόνα 14 Agent Distribution Chart flow	43
Εικόνα 15 Solver Menu.....	52
Εικόνα 16 Περιγραφή βαρδιών με 1 και 0	53
Εικόνα 17 Εργαλείο κατανομής εργαζομένων (μέρος 1)	56
Εικόνα 18 Εργαλείο κατανομής εργαζομένων (μέρος 2)	57
Εικόνα 19 Πιθανά διαλλείματα ενός οχτάωρου	59
Εικόνα 20 Πιθανά διαλλείματα ενός εξάωρου	59
Εικόνα 21 Πιθανά διαλλείματα ενός πεντάωρου	60
Εικόνα 22 Πιθανά διαλλείματα της πρώτης βάρδιας ενός οχτάωρου.....	61
Εικόνα 23 Ποσοστιαία διακύμανση κλήσεων 3/10 - 9/10	62
Εικόνα 24 Αριθμός κλήσεων που θα πραγματοποιηθούν στο τηλεφωνικό κέντρο	63
Εικόνα 25 Κατανομή κλήσεων μέσα στη μέρα.....	63
Εικόνα 26 Κατανομή κλήσεων που θέλω να απαντηθούν μέσα στη μέρα.....	64
Εικόνα 27 Ανάγκες / εργαζόμενοι 9/10.....	69
Εικόνα 28 Ανάγκες / εργαζόμενοι 8/10.....	70
Εικόνα 29 Ανάγκες / εργαζόμενοι 4/10.....	71
Εικόνα 30 Ανάγκες / εργαζόμενοι 6/10.....	72
Εικόνα 31 Διάγραμμα κλήσεων 3/10 – 16/10	75
Εικόνα 32 Διάγραμμα κλήσεων 17/10 – 30/10.....	75
Εικόνα 33 Διάγραμμα κλήσεων 31/10 – 13/11.....	76
Εικόνα 34 Διάγραμμα κλήσεων 14/11 – 27/11.....	76
Εικόνα 35 Συγκριτικό διάγραμμα μεθόδων	79
Εικόνα 36 Σύγκριση κόστους μεθοδολογιών	82
Εικόνα 37 Χρόνος που απαιτείται σε κάθε μεθοδολογία (ώρες).....	82

Περιεχόμενα Πινάκων

Πίνακας 1 Μακροπρόθεσμος σχεδιασμός	40
Πίνακας 2 Ενδεικτικός σχεδιασμός για ένα μήνα	42
Πίνακας 3 Δυνατές ώρες εργασίας κάθε οχτάωρου, εξάωρου και πεντάωρου	51
Πίνακας 4 Κατανομή εργαζομένων 9/10	64
Πίνακας 5 Κατανομή εργαζομένων 8/10	65
Πίνακας 6 Κατανομή εργαζομένων 3/10	66
Πίνακας 7 Κατανομή εργαζομένων 4/10	66
Πίνακας 8 Κατανομή εργαζομένων 5/10	67
Πίνακας 9 Κατανομή εργαζομένων 6/10	67
Πίνακας 10 Κατανομή εργαζομένων 7/10	68
Πίνακας 11 Πίνακας κλήσεων	73
Πίνακας 12 Σφάλμα sMAPE κάθε μεθόδου	77
Πίνακας 13 Σύγκριση μεθόδων με σφάλματα	79
Πίνακας 14 Ratio Εργαζόμενοι/κλήσεις	80
Πίνακας 15 Απόκλιση προτεινόμενης και υφιστάμενης μεθοδολογίας	81

1 Ευρεία Περίληψη

1.1 Η ιστορία των Τηλεφωνικών Κέντρων

Ο όρος τηλεφωνικό κέντρο αναγνωρίστηκε και δημοσιεύθηκε από το Αγγλικό Λεξικό Oxford το 1983 όπου ορίζεται ως ένα οργανωμένο σύστημα ανθρώπων, διαδικασιών και στρατηγικών, που παρέχει πρόσβαση σε πληροφορίες, πόρους και γνώσεις μέσα από κατάλληλες διόδους επικοινωνίας με σκοπό να δημιουργήσει έναν τρόπο επικοινωνίας μεταξύ της εταιρίας και των πελατών της.

Μέχρι το 1957, οι πελάτες της εκάστοτε εταιρίας έπρεπε να περιμένουν τουλάχιστον 3-4 μέρες για να πάρουν απαντήσεις σχετικά με τα ερωτήματά τους στα προϊόντα που είχαν αγοράσει ή να απευθυνθούν στο κοντινότερο κατάστημα. Για να καλύψουν αυτό το χάσμα μεταξύ εταιρίας και πελατών, όπως και για εξοικονόμηση κόστους, δημιουργήθηκαν τα τηλεφωνικά κέντρα.

Το πρώτο τηλεφωνικό κέντρο δημιουργήθηκε το 1957, από την εταιρία Life Circulation προκειμένου να αυξήσει τις πωλήσεις στο περιοδικό της. Ήταν ο πρόδρομος των σημερινών σύγχρονων τηλεφωνικών κέντρων.

Πριν τη χρήση υπολογιστών η επικοινωνία ήταν εφικτή μέσω τεράστιων κέντρων που λεγόταν Private Manual Branch Exchanges (PMBXs). Χρειάζονταν υπάλληλοι υποδοχής προκειμένου να συνδέουν χειροκίνητα τις κλήσεις και οι PMBXs συχνά χρησιμοποιούνταν από επιχειρήσεις για εξοικονόμηση χρημάτων. Αργότερα, η ενσωμάτωση των υπολογιστών στις τηλεπικοινωνίες μετέτρεψε την εναλλαγή από χειροκίνητη σε αυτόματη.


Το πρώτο τηλεφωνικό κέντρο που εγκατέστησε το PABX (Private Automated Business Exchanges), δημιουργήθηκε το 1965 από την Αγγλικής έδρας Birmingham Press and Mail. Από το 1973 και μετά, τα τηλεφωνικά κέντρα είχαν περισσότερη ζήτηση καθώς δημιουργήθηκε ο αυτόματος διαχειριστής κλήσεων (ACD). Μέχρι το τέλος του 1970, η τεχνολογία των τηλεφωνικών κέντρων εξαπλώθηκε στις τηλεφωνικές πωλήσεις, στις αεροπορικές εταιρίες για κρατήσεις και στα τραπεζικά συστήματα. Μέσα στη δεκαετία 1980 εφευρέθηκαν τα αυτοματοποιημένα τηλεφωνικά μενού (IVR) όπου ο χρήστης ακούει το ηχογραφημένο μήνυμα και μετά πατάει το αντίστοιχο κουμπί ή λέει για ποιο λόγο κάλεσε και τον κατευθύνει στο ανάλογο τμήμα. Στα μέσα της δεκαετίας 1990, όπου το διαδίκτυο εξαπλωνόταν με ταχείς ρυθμούς, εφευρέθηκε η τηλεφωνία μέσω διαδικτύου (voip), με αποτέλεσμα τη δημιουργία cloud τηλεφωνικών κέντρων. Πλέον οι εταιρίες, εκμεταλλευόμενες τις δυνατότητες που παρέχει το internet, χρησιμοποιούν ως μέσο επικοινωνίας με τους πελάτες τους εφαρμογές ανταλλαγής μηνυμάτων μέσω πλατφόρμας κοινωνικής δικτύωσης (chat) όπως επίσης και εφαρμογές απομακρυσμένης διαχείρισης.

Κατά τη δεκαετία 1990, τα τηλεφωνικά κέντρα επεκτάθηκαν και βελτιώθηκαν. Ακόμα και τώρα τα τηλεφωνικά κέντρα είναι σε αύξηση. Από το 1995 μέχρι το 2003 η βιομηχανία των τηλεφωνικών κέντρων αυξήθηκε κατά 250%. Το 2003 στο

Ηνωμένο Βασίλειο υπήρχαν 5.320 τηλεφωνικά κέντρα απασχολώντας 800.000 υπαλλήλους. Από τις αρχές του 2000 παρατηρείται ότι πολλές εταιρίες μεταφέρουν τα τηλεφωνικά τους κέντρα σε άλλες χώρες όπου το εργατικό δυναμικό είναι πιο φτηνό ή έχει καλύτερες δεξιότητες, κάνοντας έτσι πιο ελκυστικά στις εταιρίες τα offshore τηλεφωνικά κέντρα.

1.2 Αναγκαιότητα Τηλεφωνικών κέντρων

Στη σημερινή παγκόσμια οικονομία, τα τηλεφωνικά κέντρα αποτελούν βασικό τμήμα των περισσότερων εταιριών καθώς είναι ένας από τους τρόπους επικοινωνίας με τους πελάτες τους. Όπως φαίνεται στο παρακάτω διάγραμμα (αφορά έρευνα σε πολλές εταιρίες παγκοσμίως), το 47% των πελατών προτιμούν το τηλέφωνο για μέσο εξυπηρέτησης, το 17% βίντεο κλήσεις, το 21% τα μέσα κοινωνικής δικτύωσης και το 15% τα email.



ΕΙΚΟΝΑ 1 ΤΡΟΠΟΙ ΕΠΙΚΟΙΝΩΝΙΑΣ ΣΥΝΔΡΟΜΗΤΩΝ

Στην Ελλάδα έχει παρατηρηθεί ότι το ποσοστό του τηλεφώνου ως μέσο επικοινωνίας είναι μεγαλύτερο, πιθανότατα λόγω καλύτερης εξοικείωσης με αυτό και λόγω αμεσότητας.

Συγκριτικά με άλλους τρόπους επικοινωνίας, όπως η χρήση καταστημάτων, πλεονεκτεί καθώς οι πελάτες της εκάστοτε εταιρίας δεν είναι υποχρεωμένοι να μεταβούν στο κατάστημα, αλλά μπορούν να αντλήσουν τις πληροφορίες που θέλουν μέσω τηλεφώνου από όπου κι αν βρίσκονται. Επίσης, το κόστος ενός τηλεφωνικού κέντρου είναι μικρότερο από αυτό των καταστημάτων και υπάρχει η δυνατότητα άμεσης επικοινωνίας με διάφορα τμήματα της εταιρίας. Ακόμα, πλεονεκτεί στην ταχύτητα και την αποδοτικότητα, καθώς εξυπηρετώντας τους πελάτες τηλεφωνικά, οι χρόνοι αναμονής είναι μικρότεροι, οι εργαζόμενοι είναι πιο

αποδοτικοί στην επίλυση προβλημάτων και η εξυπηρέτησή τους μπορεί να γίνεται όλο το εικοσιτετράωρο. Τέλος, η ποιότητα εξυπηρέτησης είναι καλύτερη καθώς όλες οι κλήσεις ηχογραφούνται, δίνοντας την ευκαιρία στην εταιρία να ελέγχει ευκολότερα την ποιότητα της εξυπηρέτησης που παρέχει. Όπως είναι φυσικό η χρήση τηλεφωνικού κέντρου είναι αναγκαία σε κάθε εταιρία που θέλει να παρέχει υψηλό επίπεδο εξυπηρέτησης στους πελάτες της. Συγκεκριμένα, τελευταίες έρευνες έχουν δείξει ότι το 75% των επιχειρήσεων αναγνωρίζουν ότι η εξυπηρέτηση πελατών είναι ένας παράγοντας μέσα από τον οποίο μπορεί να ξεχωρίσει μια επιχείρηση και επενδύουν σε αυτό, ενώ μόλις το 25% θεωρεί ότι δεν χρειάζεται να επενδύσει σε αυτόν τον τομέα.

1.3 Διαχείριση Τηλεφωνικών Κέντρων

Λαμβάνοντας υπ' όψιν ότι το 70% του πάγιου κόστους ενός τηλεφωνικού κέντρου είναι οι εργαζόμενοί του, γίνεται αντιληπτό ότι ο πιο κρίσιμος διαχειριστικός παράγοντας σε ένα τηλεφωνικό κέντρο είναι ότι θα πρέπει να υπάρχουν αρκετοί εργαζόμενοι στις γραμμές ώστε να μπορούν να ανταποκριθούν με την μικρότερη καθυστέρηση. Συγκεκριμένα θα πρέπει να υπάρχει ο κατάλληλος αριθμός εργαζομένων κάθε περίοδο της ημέρας ώστε να καλύπτονται οι απαιτήσεις του τηλεφωνικού κέντρου ελαχιστοποιώντας το κόστος. Για να επιτευχθεί αυτό θα πρέπει πρώτα να έχει γίνει η πρόβλεψη της κίνησης με τη μικρότερη δυνατή απόκλιση και έπειτα σωστή κατανομή των εργαζομένων σε βάρδιες μέσα στη μέρα.

Η διαδικασία της διαχείρισης δυναμικού είναι περίπλοκη καθώς οι εισερχόμενες κλήσεις δεν εξαρτώνται από το κέντρο. Δεν μπορούμε να ξέρουμε πότε θα σηκώσει κάποιος πελάτης το ακουστικό και καλέσει στο τηλεφωνικό κέντρο. Στις περιπτώσεις όπου το τηλεφωνικό κέντρο διαχειρίζεται εξερχόμενες κλήσεις, που σημαίνει ότι η κίνηση είναι διαχειρίσιμη, υπάρχει πάλι η πιθανότητα να μην μπορεί να απαντήσει στην κλήση ο συνδρομητής. Ακόμα, υπάρχουν εξωγενείς παράγοντες που επηρεάζουν την κίνηση ενός κέντρου. Τέτοιοι μπορεί να είναι οι άσχημες καιρικές συνθήκες όπου σε τηλεφωνικά κέντρα τεχνικών τμημάτων αυξάνουν την κίνηση ή οι αλλαγές σε εμπορικές πολιτικές που επηρεάζουν τμήματα εξυπηρέτησης και λογαριασμών. Επίσης, εξαιρετικά δύσκολο είναι να καλυφθούν τυχόν απουσίες που πιθανόν να προκύψουν ξαφνικά προκειμένου να μπορεί να διαχειριστεί ο όγκος των κλήσεων. Σε περιπτώσεις που κάποιος δεν μπορεί να εργαστεί για κάποιο διάστημα, θα πρέπει η στελέχωση του κέντρου να είναι τέτοια ώστε να δημιουργεί ευελιξία σε αλλαγές.

Η διαχείριση ενός τηλεφωνικού κέντρου είναι ταυτόχρονα τέχνη και επιστήμη. Τέχνη καθώς στην πράξη προβλέπεις το μέλλον και επιστήμη καθώς βήμα βήμα και με μαθηματικές διαδικασίες, που χρησιμοποιούν ιστορικά δεδομένα, προβλέπεις με μεγαλύτερη ακρίβεια την μελλοντική κίνηση του κέντρου.

Η διαχείριση δυναμικού είναι κρίσιμη για την επιτυχία ενός τηλεφωνικού κέντρου και τα βασικότερα βήματα στη διαδικασία είναι τα εξής:

- Συγκέντρωση και ανάλυση ιστορικών δεδομένων
- Πρόβλεψη κίνησης
- Υπολογισμός αναγκών σε ανθρώπινο δυναμικό
- Δημιουργία προγράμματος εργαζομένων
- Παρακολούθηση και διαχείριση ημερήσιας απόδοσης

1.4 Εργαλεία Στελέχωσης Τηλεφωνικών Κέντρων

Στα πλαίσια της εργασίας έγινε αναζήτηση μεθόδων στελέχωσης τηλεφωνικών κέντρων. Σε όλα τα τηλεφωνικά κέντρα η συγκέντρωση των δεδομένων γίνεται μέσω του αυτόματου κατανεμητή κλήσεων. Εκτός από τον αριθμό εισερχόμενων κλήσεων ανά διαστήματα τετάρτου, μισής και ολόκληρης ώρας συλλέγονται δεδομένα όπως ο μέσος όρος διαχείρισης κλήσης, ο ανενεργός χρόνος ανάμεσα σε δύο κλήσεις κλπ. Για την πρόβλεψη της κίνησης έχουν εφαρμοστεί διάφοροι μέθοδοι, όπως στατιστικά μοντέλα, μοντέλα χρονοσειρών (Exponential Smoothing και ARIMA models) και νευρωνικά δίκτυα. Μετά την επιτυχή χρήση τους σε αναγνώριση φωνής και προσώπου από τη Google και την Apple, τα νευρωνικά δίκτυα αποτελούν ένα πολλά υποσχόμενο μοντέλο για την πρόβλεψη κίνησης σε τηλεφωνικά κέντρα. Ο υπολογισμός αναγκών σε ανθρώπινο δυναμικό γίνεται είτε εμπειρικά και με δοκιμές είτε με προγράμματα υλοποιημένα στις ανάγκες της εκάστοτε εταιρίας.

Προκειμένου να γίνει κατανοητή η διαδικασία στελέχωσης τηλεφωνικού κέντρου, μελετήθηκε πώς γίνεται στην πράξη σε ένα τηλεφωνικό κέντρο τηλεπικοινωνιακού παρόχου και συγκεκριμένα σε τεχνικό τμήμα σταθερής τηλεφωνίας και internet. Η συγκέντρωση των δεδομένων γίνεται μέσω του αυτόματου κατανεμητή κλήσεων, η πρόβλεψη γίνεται με εμπειρικό τρόπο και βάση της κίνησης των προηγούμενων ημερών και ο υπολογισμός αναγκών σε ανθρώπινο δυναμικό γίνεται επίσης εμπειρικά και με δοκιμές.

1.5 Σκοπός Διπλωματικής Εργασίας

Σκοπός της παρούσας διπλωματικής εργασίας, εκτός από την εύρεση μεθόδων στελέχωσης τηλεφωνικών κέντρων είναι και η βελτιστοποίησή τους. Η ραγδαία εξέλιξη της τεχνολογίας έχει συμβάλει καθοριστικά στη δημιουργία μεθόδων και εργαλείων που βασίζονται στην υπολογιστική δύναμη προκειμένου να αποφέρουν καλύτερα αποτελέσματα. Αν και αρκετές φορές η πρόβλεψη και η κατανομή εργαζομένων σε βάρδιες με εμπειρικούς και στατιστικούς τρόπους μπορεί να επιφέρει τα επιθυμητά αποτελέσματα, η χρήση εργαλείων για τα παραπάνω είναι πλέον αναγκαία. Αφενός μπορούν να παρέχουν μία πολύ καλή εκτίμηση για το άμεσο μέλλον και αφετέρου είναι ταχύτερα από τις εμπειρικές μεθόδους. Τα νευρωνικά δίκτυα είναι ήδη η πιο εξελιγμένη μέθοδος που χρησιμοποιείται από κάποιες μεγάλες εταιρίες για τεχνολογικά προϊόντα (χρησιμοποιείται για αναγνώριση φωνής, για πρόβλεψη λέξεων κατά την πληκτρολόγηση κ.α.).

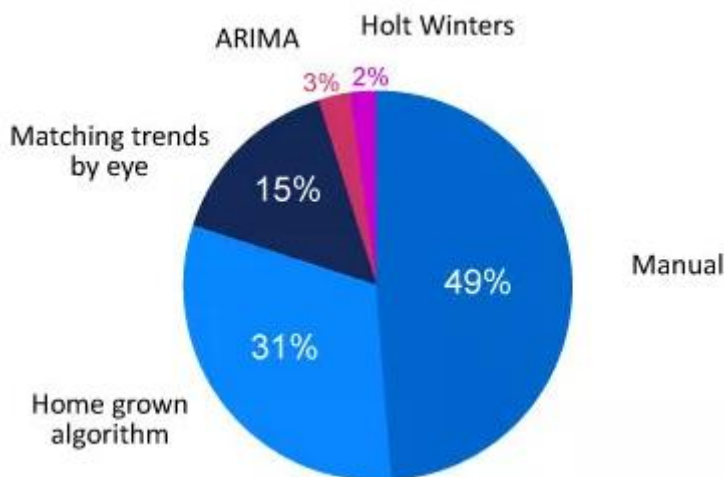
Με βάση τα παραπάνω, έγινε μελέτη για τις μεθόδους που χρησιμοποιούνται για την πρόβλεψη κίνησης σε τηλεφωνικά κέντρα. Προκειμένου να κατανοήσουμε αν τα νευρωνικά δίκτυα έχουν εφαρμογή σε αυτόν τον τομέα, χρησιμοποιήθηκαν στην πρόβλεψη κλήσεων σε τηλεφωνικό κέντρο παρόχου τηλεπικοινωνιών και έγινε σύγκριση των αποτελεσμάτων τους με τα ήδη υπάρχοντα μοντέλα. Τα νευρωνικά δίκτυα έχουν πολλά μοντέλα ανάλογα με τη χρήση και τον τρόπο πρόβλεψης. Στη διπλωματική εργασία χρησιμοποιήθηκε το μοντέλο LSTM (Long short-term memory Network). Όσον αφορά την κατανομή των εργαζομένων σε βάρδιες, αυτή γίνεται κυρίως προοδευτικά με χρήση κάποιων βοηθητικών εργαλείων όπως το Erlang C και με εργαλεία που αναπτύσσουν οι εταιρίες ώστε να καλύπτουν τις ανάγκες τους. Στον τομέα αυτό δημιουργήθηκε μια αυτοματοποιημένη μέθοδος που συλλέγει τα δεδομένα από τις προβλέψεις, κατατάσσοντας τους εργαζομένους σε βάρδιες.

2 Τεχνικές Προβλέψεων

2.1 Μοντέλα Πρόβλεψης

Σε ένα τηλεφωνικό κέντρο, η πρόβλεψη χρειάζεται τόσο για μακροπρόθεσμους όσο και για βραχυπρόθεσμους σχεδιασμούς. Έτσι, τα χαρακτηριστικά της διαδικασίας πρόβλεψης πρέπει να καθορίζονται προσεκτικά, συμπεριλαμβανομένου και του ορίζοντα πρόβλεψης. Τυπικά, μοντέλα που συνδυάζονται με χρονικές μεταβλητές είναι χρήσιμα για βραχυπρόθεσμες προβλέψεις, αφού η βαρύτητα των μεταβλητών τείνει να εξαφανίζεται σε μεγαλύτερες χρονικές περιόδους. Προκειμένου ένα μοντέλο να είναι ρεαλιστικό, χρειάζεται να είναι χρονικά εξαρτώμενο από το ρυθμό των εισερχόμενων κλήσεων, η διακύμανση των αποτελεσμάτων σε μια χρονική περίοδο να μην έχει μεγάλη απόκλιση από την πραγματική και να μπορούν να χρησιμοποιήσουν βοηθητική πληροφορία. Ταυτόχρονα, για να έχει πρακτική σημασία το μοντέλο, θα πρέπει τα δεδομένα που χρησιμοποιεί να είναι τόσα, ώστε να αποφεύγεται η υπερπροσαρμογή (overfitting) και οι παράμετροι που θα χρησιμοποιηθούν να μπορούν να υπολογιστούν εύκολα από τα δεδομένα.

Πρόσφατη έρευνα (2016) έδειξε ότι σχεδόν τα μισά τηλεφωνικά κέντρα (49%) δεν χρησιμοποιούν κάποιον αλγόριθμο αλλά η πρόβλεψη γίνεται με τη μέθοδο Naive (Manual), το 31% χρησιμοποιεί αλγόριθμο που έχουν δημιουργήσει οι ίδιοι, το 15% κάνει προβλέψεις εμπειρικά με βάση την τάση λαμβάνοντας υπόψιν τη διακύμανση των ιστορικών και μόλις το 3% και 2% χρησιμοποιούν μοντέλα ARIMA και Holt Winters αντίστοιχα.



ΕΙΚΟΝΑ 2 ΜΟΝΤΕΛΑ ΠΡΟΒΛΕΨΗΣ ΠΟΥ ΧΡΗΣΙΜΟΠΟΙΟΥΝΤΑΙ ΣΕ ΤΗΛΕΦΩΝΙΚΑ ΚΕΝΤΡΑ

Οι βασικοί τύποι μοντέλων που χρησιμοποιούνται κυρίως είναι οι παρακάτω:

Seasonal Naïve: Αυτή είναι η πιο απλή μέθοδος, όπου γίνεται η υπόθεση ότι κάθε μέρα στο μέλλον θα έχει την ίδια ή παραπλήσια κίνηση με την αντίστοιχη του παρελθόντος (π.χ. η πρώτη Δευτέρα του Απριλίου θα έχει την ίδια τιμή ή παραπλήσια με αυτήν του περσινού έτους). Το πλεονέκτημά της είναι η απλοϊκότητα στη χρήση της και το μηδαμινό κόστος της αλλά έχει το μειονέκτημα ότι δεν υπολογίζει τυχόν αυξητικές ή μειωτικές τάσεις στο μοτίβο ή σε άλλους παράγοντες.

Στατιστικά μοντέλα: Τα στατιστικά μοντέλα που χρησιμοποιούνται κυρίως είναι το μοντέλο ARIMA και το Triple Exponential Smoothing.

- ARIMA (AutoRegressive Integrated Moving Average): Πρόκειται για ένα πιο εξελιγμένο και πιο σύνθετο μοντέλο πρόβλεψης που γίνεται χρήση τα τελευταία δέκα χρόνια περίπου. Αποτελείται από τρία χαρακτηριστικά: την αυτοπαλινδρόμηση που είναι η ικανότητα να συγκρίνει δεδομένα με βάση τα προηγούμενα μοτίβα, την ενσωμάτωση που είναι η ικανότητα να συγκρίνει την τρέχουσα παρατήρηση με προηγούμενες και τον κινητό μέσο όρο που είναι η ικανότητα να εξομαλύνει τα δεδομένα των τελευταίων περιόδων. Τα πλεονεκτήματα της συγκεκριμένης μεθοδολογίας είναι η μεγάλη ευελιξία, τα ρεαλιστικά διαστήματα εμπιστοσύνης και η αμερόληπτη πρόβλεψη. Τα μειονεκτήματα είναι ότι χρειάζεται μεγάλο αριθμό δεδομένων, αρκετούς περιορισμούς και υποθέσεις και είναι δύσκολη η αυτοματοποίησή του. Οι εξισώσεις που χαρακτηρίζουν τη μέθοδο είναι:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t$$

Η οποία καθορίζει τη σχέση μεταξύ μιας παρατήρησης και των προηγούμενων p παρατηρήσεων, με φ_i την παράμετρο αυτοπαλινδρόμησης και ε_t το σφάλμα.

$$y_t^* = y_t' - y_{t-1}' = y_t - 2y_{t-1} + y_{t-2}$$

Αφορά τη διαφόριση, όπου γίνεται για μετατροπή των δεδομένων προκειμένου να γίνει στάσιμη. Αυτό βοηθάει ώστε οι παρατηρήσεις να μην εξαρτώνται από το χρόνο, εξαλείφοντας την τάση και την εποχικότητα.

$$X_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

Η παραπάνω χρησιμοποιεί την εξάρτηση ανάμεσα στις παρατηρήσεις και το υπολειπόμενο σφάλμα, όπου το q αναφέρεται στον αριθμό των προηγούμενων παρατηρήσεων που θα ληφθούν υπόψιν.

- Triple Exponential Smoothing: Γνωστό και ως μοντέλο Holt Winters, είναι μια απλή τεχνική πρόβλεψης και ένα στατιστικό μοντέλο που χρησιμοποιείται ευρέως σε τηλεφωνικά κέντρα. Συχνά λέγεται ότι είναι μια υποπερίπτωση

των μοντέλων ARIMA. Ο όρος triple σημαίνει ότι τα δεδομένα διαχωρίζονται σε τρία χαρακτηριστικά: το επίπεδο, την τάση και την εποχικότητα. Ο όρος Exponential Smoothing αναφέρεται στον τρόπο που τα δεδομένα εξομαλύνονται (εκθετικά). Το πλεονέκτημα της μεθόδου είναι ότι μπορεί να χειριστεί το επίπεδο, την τάση και την εποχικότητα των δεδομένων, μπορεί να μοντελοποιηθεί εύκολα και υπάρχει έτοιμος αλγόριθμος στο excel για τη χρήση του. Όσον αφορά τα μειονεκτήματα της μεθόδου είναι η ευαισθησία σε απότομες διακυμάνσεις και τα μικρά διαστήματα εμπιστοσύνης. Οι εξισώσεις που το χαρακτηρίζουν είναι οι παρακάτω:

$$S_t = a \frac{y_t}{I_{t-L}} + (1 - a)(S_{t-1} + b_{t-1}) \quad \text{Overall Smoothing}$$

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad \text{Trend Smoothing}$$

$$I_t = \beta \frac{y_t}{S_t} + (1 - \beta)I_{t-L} \quad \text{Seasonal Smoothing}$$

$$F_{t-m} = (S_t + mb_t)I_{t-L+m} \quad \text{Forecast}$$

Όπου γ είναι οι παρατηρήσεις, S οι εξομαλυμένες παρατηρήσεις, b ο παράγοντας τάσης, I ο παράγοντας εποχικότητας, F η πρόβλεψη για m περιόδους, το t υποδηλώνει τη χρονική περίοδο και a, β, γ οι σταθερές που πρέπει να υπολογιστούν με τέτοιο τρόπο ώστε το MSE σφάλμα να ελαχιστοποιηθεί (αυτό υπολογίζεται καλύτερα με υπολογιστικά προγράμματα).

Μηχανική μάθηση: Η εισαγωγή του κλάδου της μηχανικής μάθησης στην επιστήμη των υπολογιστών, επέτρεψε στους υπολογιστές να μπορούν να αντιμετωπίσουν προβλήματα αντίληψης για τον πραγματικό κόσμο, όσο και να παίρνουν υποκειμενικές αποφάσεις. Έτσι δημιουργήθηκαν οι αλγόριθμοι που μπορούν να αναγνωρίζουν ομοιότητες και σχέσεις μεταξύ των δεδομένων όπως και να προβλέπουν τα επόμενα γεγονότα. Τα τελευταία χρόνια χρησιμοποιούνται για πρόβλεψη καιρού, αναγνώριση προτύπων, πρόβλεψη χρονοσειρών κ.α.. Οι αλγόριθμοι που χρησιμοποιούνται στη μηχανική μάθηση είναι δέντρα αποφάσεων, η βαθιά μάθηση (deep learning), η ενισχυτική μάθηση (supervised learning), τα νευρωνικά δίκτυα και τα bayesian δίκτυα.

Σε ότι αφορά την πρόβλεψη σε τηλεφωνικά κέντρα, αυτή γίνεται με νευρωνικά δίκτυα αν και η χρήση τους είναι ακόμα περιορισμένη. Το 2009 ο Pacheco εφάρμοσε ένα βελτιωμένο νευρωνικό δίκτυο με τη μέθοδο της οπισθοδιάδοσης (Backpropagation) προκειμένου να προβλέψει τον αριθμό των εισερχόμενων κλήσεων σε ένα τηλεφωνικό κέντρο. Για κέντρα που έχουν σύνθετη συμπεριφορά, το νευρωνικό δίκτυο δείχνει να έχει καλύτερα αποτελέσματα από αυτό της εκθετικής εξομάλυνσης. Βέβαια, πολλοί όπως ο Armstrong το 2006 διαφώνησαν σχετικά με την ακρίβεια των αποτελεσμάτων των νευρωνικών δικτύων

λόγω της πολυπλοκότητας, της έλλειψης ανθεκτικότητας και διαφάνειας συγκριτικά με τα στατιστικά μοντέλα. Παρόλα αυτά, οι τελευταίες έρευνες έχουν αρχίσει να αντιμετωπίζουν τους παραπάνω περιορισμούς, χρησιμοποιώντας καλύτερες πρακτικές και φέρνοντας πιο αξιόπιστα αποτελέσματα. Από τις πιο συνηθισμένες μεθόδους είναι αυτή της πολυστρωματικής αντίληψης (MLP), της επαναλαμβανόμενης εκπαίδευσης και των ανατροφοδοτούμενων νευρωνικών δικτύων.

2.2 Δείκτες Σφάλματος

Προκειμένου να εξακριβώσουμε ποιο μοντέλο πρόβλεψης ταιριάζει στα δεδομένα μας, χρειάζεται να λάβουμε υπόψιν κριτήρια όπως η απόκλιση, η ταχύτητα και η αποτελεσματικότητα του κάθε μοντέλου. Ως μέτρο σύγκρισης χρησιμοποιούνται τα σφάλματα που υποδηλώνουν τη διαφορά μεταξύ της τιμής πρόβλεψης και της πραγματικής τιμής. Σε γενική ομολογία η μέθοδος που έχει το μικρότερο σφάλμα είναι η ακριβέστερη. Για την απόκλιση χρησιμοποιούνται δείκτες όπως το μέσο σφάλμα (Mean Error), το μέσο απόλυτο σφάλμα (Mean Absolute Error), το μέσο τετραγωνικό σφάλμα (Mean Squared Error), το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE), το MASE (Mean absolute scaled error) και το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (sMAPE).

Παρακάτω παρουσιάζονται αναλυτικά οι δείκτες που αναφέρθηκαν προηγουμένως:

i) Μέσο Σφάλμα (Mean Error)

Αναφέρεται στο μέσο όρο όλων των σφαλμάτων στο δείγμα, δηλαδή τη διαφορά μεταξύ της υπολογισθείσας τιμής και της πραγματικής. Συνήθως δεν είναι βοηθητικός αν στόχος δεν είναι η μέτρηση της προκατάληψης καθώς θετικές και αρνητικές διαφορές ακυρώνουν η μία την άλλη. Χαρακτηρίζεται από τον παρακάτω τύπο:

$$ME = \frac{1}{n} \sum_{t=1}^n (Y_t - A_t)$$

ii) Μέσο Απόλυτο Σφάλμα (Mean Absolute Error)

Όπως και στο μέσο σφάλμα, ο δείκτης αυτός αναφέρεται στο μέσο όρο των σφαλμάτων στο δείγμα με τη διαφορά ότι χρησιμοποιεί το απόλυτο της διαφοράς μεταξύ της υπολογισθείσας τιμής και της πραγματικής. Έτσι οι αρνητικές και οι θετικές διαφορές δεν ακυρώνονται μεταξύ τους. Χαρακτηρίζεται από τον τύπο:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - A_t|$$

iii) Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error)

Υπολογίζει το μέσο όρο των τετραγώνων των διαφορών μεταξύ υπολογισθείσας και πραγματικής τιμής. Αποτελεί έναν δείκτη ποιότητας,

έχει πάντα θετικό πρόσημο και οι τιμές που είναι πιο κοντά στο μηδέν είναι οι καλύτερες. Υπολογίζεται από τον τύπο:

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - A_t)^2$$

iv) MAPE

Ο δείκτης MAPE (mean absolute percentage error) είναι ο πιο συχνός δείκτης. Ταιριάζει καλύτερα όταν τα δεδομένα δεν έχουν ακραίες τιμές ή μηδενικές τιμές ή κοντά στο μηδέν. Περιγράφεται από τον παρακάτω τύπο:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - A_t|}{A_t} * 100\%$$

Όπου το A_t είναι η πραγματική τιμή και το Y_t είναι η τιμή που προβλέφθηκε από το εκάστοτε μοντέλο.

v) sMAPE

Ο δείκτης sMAPE (Symmetric mean absolute percentage error) είναι μια ακριβής μέτρηση βασισμένη σε ποσοστό σφάλματος. Η νεότερη αναφορά σε παρόμοια φόρμουλα παρουσιάστηκε από τον Armstrong (1985) όπου ονομαζόταν "adjusted MAPE" και αργότερα πήρε την τελική του μορφή από τον Flores (1986).

Η διαφορά του από τον MAPE είναι στο ότι μπορεί να χρησιμοποιηθεί και σε δεδομένα με τιμές κοντά στο μηδέν καθώς μειώνει την βαρύτητά τους. Συνήθως χαρακτηρίζεται από τον παρακάτω τύπο:

$$sMAPE = 2 * \sum_{t=1}^k \frac{|Y_t - A_t|}{|A_t + Y_t|} * 100\%$$

Όπου το A_t είναι η πραγματική τιμή και το Y_t είναι η τιμή που προβλέφθηκε από το εκάστοτε μοντέλο.

vi) MASE

Ο συγκεκριμένος δείκτης προτάθηκε το 2005 από τον Rob J. Hyndman που τον περιέγραψαν ως έναν γενικά εφαρμόσιμο δείκτη για την ακρίβεια της πρόβλεψης. Ο συγκεκριμένος δείκτης είναι ανεξάρτητος από την κλίμακα των δεδομένων και αξιοποιεί ισοδύναμα θετικά και αρνητικά σφάλματα. Περιγράφεται από τον ακόλουθο τύπο:

$$MASE = \frac{1}{T} \sum_{t=1}^T \left(\frac{|Y_t - A_t|}{\frac{1}{T-1} \sum_{t=2}^T |A_t - A_{t-1}|} \right)$$

Όπου το A_t είναι η πραγματική τιμή, το Y_t είναι η τιμή που προβλέφθηκε από το εκάστοτε μοντέλο και T το πλήθος του δείγματος.

Τέλος επειδή στην περίπτωση μας πρέπει να επιλεγεί το καλύτερο μοντέλο για τα δεδομένα που έχουμε, υπάρχει και η συνάρτηση Model fitting που χαρακτηρίζεται από τον ακόλουθο τύπο:

$$Model \ Fitting \ (MF) = n \frac{\sum_{t=1}^n (A_t - Y_t)^2}{(\sum_{t=1}^n A_t)^2} * 100\%$$


Όπου A_t είναι η πραγματική τιμή, Y_t είναι η τιμή που προβλέφθηκε από το εκάστοτε μοντέλο και n το πλήθος των δεδομένων.

2.3 Νευρωνικά Δίκτυα

2.3.1 Ορισμός

Νευρωνικό δίκτυο ονομάζεται ένα κύκλωμα διασυνδεδεμένων νευρώνων. Στην περίπτωση βιολογικών νευρώνων, πρόκειται για ένα τμήμα νευρικού ιστού. Στην περίπτωση τεχνητών νευρώνων, πρόκειται για ένα αφηρημένο αλγοριθμικό κατασκευάσμα το οποίο εμπίπτει στον τομέα της υπολογιστικής νοημοσύνης, όταν στόχος του νευρωνικού δικτύου είναι η επίλυση κάποιου υπολογιστικού προβλήματος, ή της υπολογιστικής νευροεπιστήμης, όταν στόχος είναι η υπολογιστική προσομοίωση της λειτουργίας των βιολογικών νευρωνικών δικτύων με βάση κάποιο μαθηματικό μοντέλο τους.

Το νευρωνικό δίκτυο είναι ένα δίκτυο από απλούς υπολογιστικούς κόμβους (νευρώνες), διασυνδεδεμένους μεταξύ τους. Είναι εμπνευσμένο από το Κεντρικό Νευρικό Σύστημα, το οποίο προσπαθεί να προσομοιώσει. Οι νευρώνες είναι τα δομικά στοιχεία του δικτύου. Κάθε τέτοιος κόμβος δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές (είτε από άλλους νευρώνες, είτε από το περιβάλλον), επιτελεί έναν υπολογισμό με βάση αυτές τις εισόδους και παράγει μία έξοδο. Η εν λόγω έξοδος είτε κατευθύνεται στο περιβάλλον, είτε τροφοδοτείται ως είσοδος σε άλλους νευρώνες του δικτύου. Υπάρχουν τρεις τύποι νευρώνων: οι νευρώνες εισόδου, οι νευρώνες εξόδου και οι υπολογιστικοί νευρώνες ή κρυμμένοι νευρώνες. Οι νευρώνες εισόδου δεν επιτελούν κανέναν υπολογισμό, μεσολαβούν απλώς ανάμεσα στις περιβαλλοντικές εισόδους του δικτύου και στους υπολογιστικούς νευρώνες. Οι νευρώνες εξόδου διοχετεύουν στο περιβάλλον τις τελικές αριθμητικές εξόδους του δικτύου. Οι υπολογιστικοί νευρώνες πολλαπλασιάζουν κάθε είσοδό τους με το αντίστοιχο βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων. Το άθροισμα αυτό τροφοδοτείται ως όρισμα στη συνάρτηση ενεργοποίησης, την οποία υλοποιεί εσωτερικά κάθε κόμβος. Η τιμή που λαμβάνει η συνάρτηση για το εν λόγω όρισμα είναι και η έξοδος του νευρώνα για τις τρέχουσες εισόδους και βάρη.



ΕΙΚΟΝΑ 3 ΔΟΜΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ

2.3.2 Ιδιότητες Νευρωνικών Δικτύων

Τα τελευταία χρόνια έχει υπάρξει μία έκρηξη ενδιαφέροντος για τα νευρωνικά δίκτυα καθώς εφαρμόζονται με μεγάλη επιτυχία σε ένα ασυνήθιστα μεγάλο φάσμα τομέων της επιστήμης και της τεχνολογίας, όπως τα χρηματοοικονομικά, η ιατρική, η επιστήμη μηχανικού, η γεωλογία, η φυσική, η ρομποτική, η επεξεργασία σήματος κτλ. Στην πραγματικότητα, τα νευρωνικά δίκτυα εισάγονται οπουδήποτε τίθεται θέμα πρόβλεψης, ταξινόμησης ή ελέγχου. Η σαρωτική αυτή επιτυχία, μπορεί να αποδοθεί σε δύο βασικά στοιχεία: την ισχύ και την ευχρηστία.

Ισχύς: Τα νευρωνικά δίκτυα είναι πολύ εξελιγμένες τεχνικές μη γραμμικής μοντελοποίησης, ικανές να μοντελοποιήσουν εξαιρετικά πολύπλοκες λειτουργίες. Η γραμμική μοντελοποίηση υπήρξε ευρέως διαδεδομένη για πολύ καιρό, δεδομένου ότι στα γραμμικά μοντέλα εφαρμόζονται πολύ γνωστές στρατηγικές βελτιστοποίησης. Στις συνήθειες, όμως, περιπτώσεις όπου η γραμμική προσέγγιση δεν ήταν έγκυρη, τα μοντέλα αυτά αποτύγχαναν αναλόγως. Τα νευρωνικά δίκτυα βέβαια, αν και επιτρέπουν τη μη γραμμικότητα μέσω χρήσης μη γραμμικών συναρτήσεων ενεργοποίησης, μεταθέτουν με τη σειρά τους το πρόβλημα στο ζήτημα της διάστασης (του πλήθους των διαφορετικών εισόδων και εξόδων), το οποίο αποτελεί αγκάθι στις προσπάθειες μοντελοποίησης μη γραμμικών συναρτήσεων με μεγάλο αριθμό μεταβλητών.

Ευχρηστία: Τα νευρωνικά δίκτυα εκπαιδεύονται με παραδείγματα. Ο χρήστης συγκεντρώνει αντιπροσωπευτικά δεδομένα και στη συνέχεια, καθώς τα τροφοδοτεί συστηματικά στο δίκτυο μέσω των κατάλληλων αλγορίθμων εκπαίδευσης, το δίκτυο «αντιλαμβάνεται» αυτομάτως τη δομή των δεδομένων και η «γνώση» αυτή εκφράζεται ως κατάλληλες επιλογές βαρών. Επομένως το τελικό αποτέλεσμα της εκπαίδευσης με ένα συγκεκριμένο σύνολο παραδειγμάτων είναι ο προσδιορισμός των κατάλληλων βαρών του δικτύου. Ο χρήστης χρειάζεται να έχει κάποιες ουσιώδεις γνώσεις σχετικά με τον τρόπο επιλογής και προετοιμασίας των δεδομένων, τον τρόπο εκλογής του κατάλληλου νευρωνικού δικτύου και στο πώς θα ερμηνευτούν τα αποτελέσματα. Παρά ταύτα, το επίπεδο των γνώσεων του χρήστη που απαιτούνται για μια επιτυχημένη εφαρμογή των νευρωνικών δικτύων, είναι πολύ χαμηλότερο συγκριτικά με κάποια περίπτωση που θα χρησιμοποιούνταν ορισμένες πιο παραδοσιακές, μη γραμμικές στατιστικές μέθοδοι.

2.3.3 Εκπαίδευση Νευρωνικών Δικτύων

Μια από τις πιο βασικές ιδιότητες των Νευρωνικών Δικτύων είναι η ικανότητά τους για εκπαίδευση. Η εκπαίδευση αυτή επιτυγχάνεται μέσω της ανταλλαγής τιμών και βαρών, που αποσκοπεί στη βαθμιαία σύλληψη της πληροφορίας η οποία στη συνέχεια θα είναι διαθέσιμη προς ανάκτηση. Υπάρχουν, βέβαια, πολλοί αλγόριθμοι που η εφαρμογή τους έχει στόχο την προσαρμογή των τιμών των βαρών ενός Τεχνητού Νευρωνικού Δικτύου. Όλες οι μέθοδοι μάθησης μπορούν να καταταχθούν σε δύο κατηγορίες : τη μάθηση με επίβλεψη (supervised learning) και τη μάθηση χωρίς επίβλεψη (unsupervised learning).

Μάθηση με επίβλεψη: Η μάθηση αυτή είναι μια διαδικασία η οποία συνδυάζει έναν εξωτερικό εκπαιδευτή και τη συνολική ή γενικευμένη πληροφορία. Κάποιες από τις μεθόδους οι οποίες συγκαταλέγονται σε αυτή την κατηγορία είναι η μάθηση με διόρθωση σφάλματος, η στοχαστική μάθηση. Παραδείγματα τα οποία αντιπροσωπεύουν την μάθηση με επίβλεψη συμπεριλαμβάνουν αποφάσεις για το πότε θα πρέπει να σταματήσει η διαδικασία εκπαίδευσης, αποφάσεις αναφορικά με τη συχνότητα παρουσίασης στο δίκτυο, τα πρότυπα εκπαίδευσης και την παρουσίαση προόδου του δικτύου. Η μάθηση με επίβλεψη χωρίζεται σε δύο ακόμα κατηγορίες: στη δομική (structural) και στην προσωρινή (temporal) εκμάθηση. Οι αλγόριθμοι οι οποίοι βρίσκονται στην πρώτη κατηγορία, χρησιμοποιούνται για την εύρεση της βέλτιστης σχέσης μεταξύ εισόδων και εξόδων για κάθε ξεχωριστό ζευγάρι προτύπων. Παραδείγματα της δομικής εκμάθησης αποτελούν η αναγνώριση και η κατηγοριοποίηση προτύπων, ενώ παραδείγματα της προσωρινής εκμάθησης η πρόβλεψη και ο έλεγχος.

Μάθηση χωρίς επίβλεψη: Οι αλγόριθμοι της εν λόγω μάθησης αναφέρονται ως αυτο-οργανωμένοι (self-organized) και είναι διαδικασίες οι οποίες δεν απαιτούν να είναι παρών ένας «εξωτερικός» δάσκαλος ή επιβλέπων. Βασίζονται, μάλιστα, μόνο σε τοπική πληροφορία καθ' όλη τη διάρκεια της εκπαίδευσης του Τεχνητού Νευρωνικού Δικτύου. Οι συγκεκριμένοι αλγόριθμοι οργανώνουν τα δεδομένα και ανακαλύπτουν τις σημαντικές συλλογικές ιδιότητες. Για παράδειγμα, αλγόριθμοι εκπαίδευσης χωρίς επίβλεψη είναι ο αλγόριθμος Hebbian, ο διαφορικός αλγόριθμος Hebbian και ο Min - Max αλγόριθμος.


Κατά κύριο λόγο οι περισσότερες διαδικασίες εκπαίδευσης είναι offline. Όταν χρησιμοποιείται όλο το δείγμα προτύπων για την τροποποίηση των τιμών των βαρών, πριν την τελική χρήση του δικτύου ως εφαρμογή, τότε ονομάζεται offline εκπαίδευση. Οι αλγόριθμοι εκπαίδευσης offline έχουν την απαίτηση να βρίσκονται στην εκπαίδευση του δικτύου παρόντα όλα τα πρότυπα. Το γεγονός αυτό αποκλείει την πιθανότητα εισαγωγής νέων πληροφοριών μέσω νέων προτύπων. Βέβαια, υπάρχουν και Τεχνητά Νευρωνικά Δίκτυα τα οποία δεν αποκλείουν την εισαγωγή νέας πληροφορίας, μετά την τελική τους μοντελοποίηση. Αν παρουσιαστεί ανάγκη εισαγωγής νέου προτύπου στο δίκτυο, μπορεί να γίνει απευθείας χωρίς τον κίνδυνο να χαθεί κανένα μέρος της αρχικής πληροφορίας. Το πλεονέκτημα των δικτύων που

χρησιμοποιούν offline διαδικασίες εκπαίδευσης επικεντρώνεται κυρίως στη δυνατότητα να δίνουν καλύτερες λύσεις σε δύσκολα προβλήματα.

2.3.4 Κατηγορίες Νευρωνικών Δικτύων

Feedforward Neural Network

Αποτελούν τον πρώτο και πιο απλό τύπο νευρωνικών δικτύων. Σε αυτά τα δίκτυα, η πληροφορία μεταφέρεται προς μία κατεύθυνση, από τους κόμβους εισόδου, μέσω των κρυφών κόμβων (εάν υπάρχουν) προς τους κόμβους εξόδου. Δεν υπάρχουν βρόχοι σε αυτόν τον τύπο δικτύων.




ΕΙΚΟΝΑ 4 ΔΟΜΗ FEEDFORWARD NEURAL NETWORK

Η απλούστερη μορφή νευρωνικών δικτύων είναι αυτά που δεν έχουν κρυφούς κόμβους (hidden Layers) και ονομάζονται single layer perceptron. Σε αυτά οι είσοδοι τροφοδοτούνται απευθείας στις εξόδους μέσω κάποιων βαρών. Ένας νευρώνας μπορεί να δημιουργηθεί χρησιμοποιώντας τιμές για ενεργοποιημένα ή απενεργοποιημένα στάδια. Ένας νευρώνας μπορεί να εκπαιδευτεί από έναν αλγόριθμο που συνήθως ονομάζεται κανόνας δέλτα (delta rule). Υπολογίζει τα σφάλματα μεταξύ των υπολογισμένων τιμών εξόδου και αυτά του δείγματος και τα χρησιμοποιεί για να προσαρμόσει τα αντίστοιχα βάρη. Οι νευρώνες που αποτελούνται από μία μονάδα είναι ικανοί να μαθαίνουν μόνο γραμμικά διαχωρίσιμα μοτίβα. Το 1969 ο Marvin Minsky και ο Seymour Papert έδειξαν ότι είναι αδύνατον για να μάθουν μία XOR συνάρτηση (σε αντίθεση με τους πολυστρωματικούς νευρώνες που είναι ικανοί να παράγουν boolean συναρτήσεις). Αν και οι νευρώνες που αποτελούνται από μία μονάδα είναι περιορισμένοι στην υπολογιστική τους ισχύ, έχει αποδειχτεί ότι δίκτυα με παράλληλες μονάδες μπορούν να προσεγγίσουν συνεχείς συναρτήσεις πραγματικών αριθμών σε διάστημα από -1 έως 1 όπως απέδειξαν οι Peter Auer, Harald Burgsteiner και Wolfgang Maass.

Recurrent Neural Network

Η ιδέα πίσω από τα ανατροφοδοτούμενα νευρωνικά δίκτυα είναι να γίνεται χρήση της διαδοχικής πληροφορίας. Σε ένα παραδοσιακό νευρωνικό δίκτυο υποθέτουμε ότι όλοι οι εισοδοί είναι ανεξάρτητοι μεταξύ τους. Αλλά σε κάποιες εφαρμογές των νευρωνικών δικτύων δεν εξυπηρετεί. Πχ αν χρειάζεται να προβλέψεις μία λέξη σε μία πρόταση, πρέπει να ξέρεις τις λέξεις που έχουν προηγηθεί. Ονομάζονται ανατροφοδοτούμενα καθώς πραγματοποιούν την ίδια διεργασία για κάθε στοιχείο της ακολουθίας, με την έξοδο να είναι εξαρτώμενη από τους προηγούμενους υπολογισμούς. Ένας άλλος τρόπος κατανόησής τους είναι ότι έχουν «μνήμη» που αποθηκεύουν τους προηγούμενούς τους υπολογισμούς. Στη θεωρία, τα ανατροφοδοτούμενα νευρωνικά δίκτυα μπορούν να χρησιμοποιήσουν πληροφορία σε αυθαίρετα μεγάλο αριθμό δεδομένων, αλλά στην πράξη έχουν τον περιορισμό να ελέγχουν ένα μικρότερο διάστημα.



ΕΙΚΟΝΑ 5 ΔΟΜΗ RECURRENT NEURAL NETWORK

Το παραπάνω διάγραμμα δείχνει πως ένα ανατροφοδοτούμενο νευρωνικό δίκτυο λειτουργεί. Για παράδειγμα, εάν η ακολουθία που μας ενδιαφέρει είναι μία πρόταση 5 λέξεων, το δίκτυο θα “ξεδιπλωθεί” σε ένα δίκτυο 5 νευρώνων, έναν για κάθε λέξη. Σε κάθε νευρώνα η φόρμουλα που χρησιμοποιείται για τον υπολογισμό είναι:

x_t : η τιμή εισόδου με χρονικό βήμα t .

s_t : η κρυφή κατάσταση το χρονικό βήμα t , είναι η «μνήμη» του δικτύου και υπολογίζεται βάσει του προηγούμενου κρυφού βήματος και της τιμής εισόδου σε αυτό το βήμα.

o_t : η έξοδος του βήματος t .

Συγκριτικά με τα παραδοσιακά νευρωνικά δίκτυα, που χρησιμοποιούν διαφορετικές παραμέτρους για κάθε νευρώνα, τα ανατροφοδοτούμενα δίκτυα μοιράζονται τις ίδιες παραμέτρους σε όλα τα βήματα.

Η εκπαίδευση ενός ανατροφοδοτούμενου δικτύου είναι παρόμοια με αυτή ενός παραδοσιακού νευρωνικού δικτύου. Συνήθως χρησιμοποιείται ο αλγόριθμος


οπισθοδιάδοσης (backpropagation). Επειδή οι παράμετροι είναι διαμοιρασμένοι σε χρονικά βήματα μέσα στο δίκτυο, η κλίση για κάθε έξοδο δεν εξαρτάται μόνο από τους υπολογισμούς τη συγκεκριμένη χρονική στιγμή, αλλά και από τις προηγούμενες χρονικές στιγμές.

Long short-term memory Network


Τα Long short-term memory (LSTM) δίκτυα είναι μια κατηγορία των ανατροφοδοτούμενων νευρωνικών δικτύων. Εισήχθησαν από τους Hochreiter και Schmidhuber το 1997 και βελτιώθηκαν το 2000 από την ομάδα του Felix Ger. Λειτουργούν εξαιρετικά σε μεγάλη ποικιλία προβλημάτων και πλέον χρησιμοποιούνται ευρέως. Από το 2016 και μετά, μεγάλες εταιρίες όπως Google, Apple και Microsoft χρησιμοποιούν αυτού του είδους τα δίκτυα στα προϊόντα τους (για παράδειγμα η Google τα χρησιμοποιεί στην αναγνώριση ομιλίας στα κινητά και στο Google translate, η Apple στην εφαρμογή Quicktype και στη Siri). Είναι λεπτομερώς σχεδιασμένα για να θυμούνται πληροφορίες για μεγάλες χρονικές περιόδους.

Ένα συνηθισμένο LSTM δίκτυο αποτελείται από την κυψέλη (cell), την είσοδο (input gate), την έξοδο (output gate) και την πύλη διαγραφής (forget gate). Η κυψέλη είναι υπεύθυνη για να «θυμάται» τιμές σε τυχαία χρονικά διαστήματα, εξ ου και ο όρος memory. Κάθε μία από τις τρεις πύλες μπορεί να χαρακτηριστεί ως ένα «συμβατικό» νευρωνικό δίκτυο. Η έκφραση long short-term αναφέρεται στο γεγονός ότι το LSTM είναι ένα μοντέλο για χρονικά μικρή μνήμη που μπορεί να διαρκέσει μεγάλο χρονικό διάστημα. Αυτό το δίκτυο ταιριάζει απόλυτα στην πρόβλεψη χρονοσειρών.

Όπως όλα τα ανατροφοδοτούμενα δίκτυα, έτσι και το LSTM χρησιμοποιεί μια αλυσίδα από επαναλαμβανόμενους «θαλάμους». Η διαφορά τους έγκειται στο ότι η δομή ενός «θαλάμου» ανατροφοδοτούμενου δικτύου είναι πιο απλή από αυτή του LSTM (πχ μπορεί να περιέχει μία μόνο εξίσωση), ενώ στο LSTM περιέχονται παραπάνω από μία εξισώσεις.




ΕΙΚΟΝΑ 6 ΕΠΑΝΑΛΑΜΒΑΝΟΜΕΝΗ ΔΟΜΗ ΣΕ ΑΠΛΟ RNN



ΕΙΚΟΝΑ 7 ΕΠΑΝΑΛΑΜΒΑΝΟΜΕΝΗ ΔΟΜΗ ΣΕ LSTM


Στο παραπάνω διάγραμμα, κάθε γραμμή μεταφέρει ένα διάνυσμα από την έξοδο του ενός νευρώνα στην είσοδο του άλλου. Οι ροζ κύκλοι αφορούν την κατεύθυνση των διεργασιών και τα κίτρινα κουτιά είναι τα γνωστά στρώματα του δικτύου.

Το κλειδί είναι το στάδιο της κυψέλης (cell state), δηλαδή η οριζόντια γραμμή στο πάνω μέρος του διαγράμματος. Περνάει από όλη την αλυσίδα, κάνοντας μικρές γραμμικές αλληλεπιδράσεις όπως φαίνεται στην παρακάτω εικόνα.



ΕΙΚΟΝΑ 8 CELL STATE


Το δίκτυο έχει τη δυνατότητα να αφαιρέσει ή να προσθέσει πληροφορία στο στάδιο της «κυψέλης» ελεγχόμενα από τις πύλες. Οι πύλες είναι ο τρόπος ώστε να αφήνουν να περνούν οι πληροφορίες επιλεκτικά και είναι συγκροτημένα από σιγμοειδείς στρώσεις και από μία πολλαπλασιαστική λειτουργία όπως φαίνεται παρακάτω.



ΕΙΚΟΝΑ 9 ΔΟΜΗ ΠΥΛΗΣ


Μία σιγμοειδής στρώση εξάγει αριθμούς ανάμεσα σε 0 και 1, περιγράφοντας κατά πόσον ένα στοιχείο πρέπει να περάσει. Η τιμή 0 σημαίνει ότι δεν περνάει, ενώ η τιμή ένα ότι περνάνε όλα. Συνήθως ένα δίκτυο έχει τρεις τέτοιες πύλες προκειμένου να προστατεύει και να ελέγχει την «κυψέλη».

Το πρώτο βήμα σε ένα LSTM δίκτυο είναι να αποφασίσουμε ποιες πληροφορίες θα κρατήσουμε και ποιες όχι από την κυψέλη. Αυτή η απόφαση γίνεται από τη σιγμοειδή στρώση και ονομάζεται “forget gate layer”. Ελέγχει τις τιμές h_{t-1} και x_t και εξάγει έναν αριθμό από 0 έως 1 για κάθε τιμή στην κυψέλη, όπως φαίνεται στην παρακάτω εικόνα.



ΕΙΚΟΝΑ 10 FORGET GATE LAYER


Το επόμενο βήμα είναι να αποφασιστεί ποια πληροφορία θα αποθηκευτεί στην κυψέλη. Αυτό έχει δύο μέρη. Πρώτα, μία σιγμοειδή στρώση που ονομάζεται πύλη εισόδου (input gate layer) και αποφασίζει ποιες τιμές θα αναβαθμιστούν. Έπειτα υπάρχει η tanh στρώση που δημιουργεί ένα διάνυσμα για τις υποψήφιες τιμές που θα εισαχθούν στην κυψέλη. Τέλος συνδυάζοντας τα παραπάνω δημιουργείται η αναβαθμισμένη τιμή στην κυψέλη.



ΕΙΚΟΝΑ 11 ΔΗΜΙΟΥΡΓΙΑ ΑΝΑΒΑΘΜΙΣΜΕΝΗΣ ΤΙΜΗΣ ΣΤΗΝ ΚΥΨΕΛΗ

Τέλος θα πρέπει να δούμε τι θα έχουμε για έξοδο. Η τιμή αυτή θα βασίζεται στην τιμή της κυψέλης, αλλά μπορεί και να φιλτραρισθεί πρώτα. Πρώτα περνάει μέσα από τη σιγμοειδή βαθμίδα για να αποφασιστεί ποιες τιμές της κυψέλης θα έχουμε για έξοδο. Έπειτα μεσολαβεί η tanh προκειμένου να μετατραπούν οι τιμές

στο διάστημα -1 έως 1 και σε συνδυασμό με τη σιγμοειδή βαθμίδα έχουμε για έξοδο μόνο τις τιμές που μας ενδιαφέρουν.



ΕΙΚΟΝΑ 12 ΕΞΟΔΟΣ

Παραπάνω περιγράφεται μία γενική μορφή LSTM δικτύου, αλλά υπάρχουν διαφοροποιήσεις ανάλογα με τη λειτουργία που αποσκοπούν.

3 Πραγματική Εφαρμογή σε Τηλεφωνικό Κέντρο

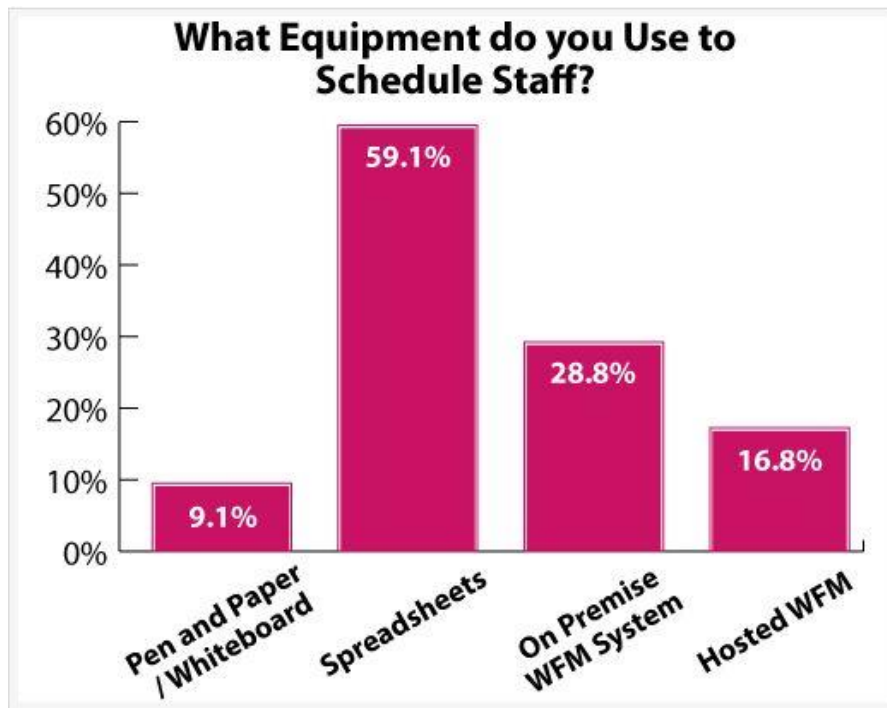
3.1 Επισκόπηση Εφαρμογής και Διαθέσιμα Δεδομένα

Παράλληλα με τη θεωρητική έρευνα για την πρόβλεψη της κίνησης σε τηλεφωνικό κέντρο, πραγματοποιήθηκε προσομοίωση των μοντέλων που αναλύθηκαν προηγουμένως σε τηλεφωνικό κέντρο τηλεπικοινωνιακού παρόχου και συγκεκριμένα σε τεχνικό τμήμα σταθερής τηλεφωνίας και internet. Το συγκεκριμένο τμήμα δέχεται κλήσεις από τους συνδρομητές για τεχνικές βλάβες σε υπηρεσίες τηλεφωνίας, ίντερνετ και τηλεόρασης. Οι εργαζόμενοι απαντούν τις κλήσεις και μέσα σε ένα χρονικό διάστημα που θέτει η εταιρία θα πρέπει να επιλύσουν τη βλάβη ή να ενημερώσουν τον συνδρομητή για τις ενέργειες που έχουν γίνει σε περίπτωση που διαχειρίζεται ήδη και να καταγράψουν τις ενέργειες που έκαναν. Αυτό το χρονικό διάστημα αποτελείται από τον ενεργό χρόνο κλήσης και από τον ανενεργό χρόνο καταγραφής και φανερώνει τον αριθμό των κλήσεων που θα απαντηθούν βάση της δύναμης του κέντρου.

Εκτός από τον τρόπο λειτουργίας του τηλεφωνικού κέντρου, μελετήθηκε και η μέθοδος πρόβλεψης των εισερχόμενων κλήσεων και ο τρόπος κατανομής των εργαζομένων σε βάρδιες που χρησιμοποιείται στην εταιρία. Αξίζει να σημειωθεί ότι εξίσου σημαντικό με την πρόβλεψη της κίνησης σε ένα τηλεφωνικό κέντρο είναι ο προγραμματισμός των ωραρίων των εργαζομένων. Θα πρέπει να καλύπτονται οι ανάγκες του κέντρου μέσα στη μέρα και ταυτόχρονα να είναι μέσα στα νομοθετικά πλαίσια κάθε χώρας. Για την Ελλάδα θα πρέπει π.χ. ο κάθε εργαζόμενος να δουλεύει πέντε μέρες τη βδομάδα, να μεσολαβεί ένα διάστημα έντεκα ωρών μεταξύ των βαρδιών του και να έχει τις προβλεπόμενες μέρες αδείας μέσα στο χρόνο. Ο υπολογισμός γίνεται βασιζόμενος στη πρόβλεψη της κίνησης, εξαρτάται από τις ανάγκες του εκάστοτε τηλεφωνικού κέντρου και εφαρμόζεται τόσο μακροπρόθεσμα, όσο και βραχυπρόθεσμα. Ο μακροπρόθεσμος σχεδιασμός είναι απαραίτητος καθώς χρειάζεται ένα χρονικό διάστημα για την πρόσληψη των απαραίτητων εργαζομένων καθώς και για την εκπαίδευσή τους. Ο βραχυπρόθεσμος είναι απαραίτητος καθώς θα πρέπει να κατανεμηθούν σωστά οι εργαζόμενοι σε βάρδιες προκειμένου να απαντηθούν οι κλήσεις που έχουν υπολογισθεί.

Σε ότι αφορά το μακροπρόθεσμο σχεδιασμό χρησιμοποιούνται κυρίως στατιστικές μέθοδοι που στηρίζονται στην πρόβλεψη ανά μήνα και στις ανάγκες του κέντρου. Ο βραχυπρόθεσμος σχεδιασμός γίνεται με προγράμματα που υπάρχουν στο εμπόριο, είτε μέσω του εργαλείου Erlang C (το οποίο αξιοποιεί τα διαθέσιμα δεδομένα όπως η πρόβλεψη των εισερχόμενων κλήσεων, ο μέσος χρόνος διαχείρισης κ.α. και υπολογίζει τον αριθμό των εργαζομένων που χρειάζονται, το επίπεδο εξυπηρέτησης κ.λπ.) και σε κάποιες περιπτώσεις με συνδυασμό εμπειρικών και στατιστικών μεθόδων. Βέβαια κάποιες εταιρίες έχουν δημιουργήσει δικό τους πρόγραμμα που εξυπηρετεί τις ανάγκες τους. Πρόσφατη έρευνα (2017), δείχνει ότι λίγες είναι οι επιχειρήσεις που χρησιμοποιούν ολοκληρωμένα

προγράμματα υπολογισμού των βαρδιών, καθώς οι περισσότερες προτιμούν απλές μεθόδους, όπως το Excel.



ΕΙΚΟΝΑ 13 ΤΡΟΠΟΙ ΥΠΟΛΟΓΙΣΜΟΥ ΤΟΥ WFM (2017)

Εκτός από τη μελέτη του τρόπου λειτουργίας του συγκεκριμένου κέντρου, εφαρμόστηκαν οι μεθοδολογίες πρόβλεψης που αναφέρθηκαν προηγουμένως και έγινε σύγκριση των αποτελεσμάτων μεταξύ των μεθόδων που εφαρμόστηκαν και της μεθόδου που χρησιμοποιείται στην εταιρία που έγινε η μελέτη.

Τα διαθέσιμα δεδομένα είναι:

- Ημερήσιος αριθμός κλήσεων για το διάστημα 1/1/2014 έως 31/12/2016.
- Η ωριαία πρόβλεψη κίνησης κατά τη διάρκεια της μέρας για το διάστημα 1/10/2016 έως 31/11/2016.
- Αριθμός εργαζομένων για το διάστημα 1/10/2016 έως 31/11/2016.
- Πρόβλεψη κίνησης που έγινε από την εταιρία στο διάστημα 1/10/2016 έως 31/11/2016.
- Η κατανομή των εργαζομένων στο διάστημα 1/10/2016 έως 31/11/2016.

3.2 Υφιστάμενη Μεθοδολογία Πρόβλεψης και Στελέχωσης

3.2.1 Υφιστάμενη Μεθοδολογία Πρόβλεψης Εισερχόμενων Κλήσεων

Η πρόβλεψη των εισερχόμενων κλήσεων στο τηλεφωνικό κέντρο που έγινε η μελέτη γίνεται με τη μέθοδο Naïve. Πιο συγκεκριμένα, γίνεται τόσο μακροπρόθεσμη όσο και βραχυπρόθεσμη πρόβλεψη. Στην πρώτη περίπτωση βασίζονται στην πελατειακή βάση και στην ιστορικότητα και γίνεται η πρόβλεψη για τις κλήσεις που θα δεχτούν ανά μήνα. Αν για παράδειγμα αναμένουν αύξηση της πελατειακής βάσης λόγω αλλαγής στην πολιτική των πωλήσεων, ο αριθμός των κλήσεων αναμένεται να αυξηθεί σε αντίστοιχο ποσοστό συγκριτικά με αυτές του προηγούμενου μήνα. Σε ότι αφορά τη βραχυπρόθεσμη πρόβλεψη, παρατηρώντας τον αριθμό των κλήσεων τόσο στο διάστημα των τελευταίων δύο εβδομάδων όσο και στις αντίστοιχες περιόδους τα προηγούμενα χρόνια γίνεται η πρόβλεψη για τις επόμενες μέρες. Επίσης, σημαντικός παράγοντας που επηρεάζει την πρόβλεψη είναι και σε αυτή την περίπτωση η πελατειακή βάση της εταιρίας. Αν για παράδειγμα υπάρχει αύξηση 5% στην πελατειακή βάση συγκριτικά με την προηγούμενη χρονιά, θα υπάρχει και αντίστοιχη αύξηση στον αριθμό των κλήσεων. Τέλος, λαμβάνονται υπόψιν και πιθανοί εξωτερικοί παράγοντες που μπορούν να επηρεάσουν τον αριθμό των κλήσεων, όπως για παράδειγμα στην περίπτωσή μας (τμήμα επίλυσης τεχνικών βλαβών) είναι η επιδείνωση των καιρικών φαινομένων που δημιουργεί καλωδιακές βλάβες ή μια προγραμματισμένη εργασία που θα επηρεάσει μεγάλο αριθμό πελατών και όσοι δεν έχουν ενημερωθεί θα καλέσουν στο τηλεφωνικό κέντρο.

3.2.2 Υφιστάμενη Μεθοδολογία Στελέχωσης Προσωπικού

Απώτερος στόχος όλων των παραπάνω είναι η σωστή πρόβλεψη σε ανάγκες προσωπικού και η βέλτιστη κατανομή τους σε βάρδιες. Όπως και στην πρόβλεψη των κλήσεων, έτσι και εδώ γίνεται σχεδιασμός τόσο σε μακροπρόθεση όσο και σε βραχυπρόθεσμη κλίμακα. Μακροπρόθεσμα γίνεται η αποτύπωση των αναγκών σε προσωπικό ανά μήνα και βραχυπρόθεσμα η κατανομή τους σε βάρδιες μέσα στη μέρα.

Ι. Μακροπρόθεσμη κλίμακα: Όπως αναφέρθηκε προηγουμένως, ο μακροπρόθεσμος σχεδιασμός αναφέρεται σε μηνιαία κλίμακα και αφορά ένα οικονομικό έτος. Στηρίζεται στην μηνιαία πρόβλεψη εισερχόμενων κλήσεων και σε στόχους του κέντρου, όπως ο μέσος χρόνος διαχείρισης, η παραγωγικότητα κ.α.. Στην εταιρία που έγινε η έρευνα, δεν χρησιμοποιείται κάποιο εξειδικευμένο πρόγραμμα, αλλά βασίζεται στα στοιχεία που αναφέρονται παρακάτω:

ΠΙΝΑΚΑΣ 1 ΜΑΚΡΟΠΡΟΘΕΣΜΟΣ ΣΧΕΔΙΑΣΜΟΣ

		Month 1	Month 2	Month 3
Calls	Calls			
	Answered			
	AHT			
	ACR			
Shrinkage	Planning shrinkage			
KPIs	Working Days			
	Working days			
	Monthly Calls per FTE			
	Total min/FTE			
	Productivity			
	Productive min			
	Productive sec			
	Calls			
	Manpower demands			

Ο εν λόγω πίνακας χωρίζεται σε δύο υποπίνακες, τον πρώτο που αφορά τον αριθμό των κλήσεων και τον δεύτερο που αναφέρεται στον δείκτη παραγωγικότητας. Πιο συγκεκριμένα οι μεταβλητές που αξιοποιούνται για τον προγραμματισμό είναι οι ακόλουθες:

- **Calls:** ο αριθμός των κλήσεων που έχει προβλεφθεί για τον εκάστοτε μήνα.
- **Answered:** ο αριθμός των εισερχόμενων κλήσεων που θέλουμε να απαντηθούν και ορίζεται από το ACR (abandon call rate) που έχει το κάθε τμήμα.
- **AHT (Average Handling Time):** ο μέσος χρόνος διαχείρισης κάθε κλήσης.
- **ACR (abandon call rate):** ποσοστό των χαμένων κλήσεων προς τις συνολικές κλήσεις που εισέρχονται στο τηλεφωνικό κέντρο. Στην πλειοψηφία των τηλεφωνικών κέντρων το ACR θα πρέπει να είναι το πολύ 5%.
- **Planning shrinkage:** ο χρόνος όπου ο εργαζόμενος δεν απαντά κλήσεις (άδειες, εκπαιδεύσεις κ.λ.π.)
- **Working Days:** εργάσιμες μέρες του μήνα ανά εργαζόμενο.
- **Working days:** ο αριθμός των ημερών που θα δουλεύει ο εργαζόμενος αφαιρώντας το shrinkage ($Working\ Days * (1 - shrinkage)$).
- **Monthly Calls per FTE:** ο συνολικός αριθμός των κλήσεων που θα διαχειριστεί ένας 8ωρος εργαζόμενος μέσα στο μήνα. Υπολογίζεται ως το γινόμενο των κλήσεων που διαχειρίζεται μέσα στη μέρα (calls) επί το Working days.
- **Total min/FTE:** Τα συνολικά λεπτά που εργάζεται ένας οχτάωρος σε κάθε βάρδια (8x60)
- **Productivity:** Ο καθαρά παραγωγικός χρόνος του κάθε εργαζόμενου μέσα στη βάρδια. Στατιστικές έχουν δείξει ότι όταν το ACR είναι 5% η μέση

παραγωγικότητα του εργαζόμενου είναι στο 65%. Για κάθε 1% μείωσης του ACR η παραγωγικότητα αυξάνεται κατά 5% και το αντίστροφο.

- Productive min: Είναι το γινόμενο των συνολικών λεπτών ενός οχτάωρου επί το Productivity.
- Productive sec: Είναι ο παραγωγικός χρόνος ενός οχτάωρου σε δευτερόλεπτα.
- Calls: Είναι ο αριθμός των κλήσεων που μπορεί να απαντήσει ένας οχτάωρος μέσα στη βάρδια του. Υπολογίζεται ως πηλίκο των productive sec προς το ΑΗΤ.
- Manpower demands: Καθορίζει τις ανάγκες του κέντρου σε άτομα και υπολογίζεται ως το πηλίκο των κλήσεων που θέλουμε να απαντηθούν (Answered calls) προς τον αριθμό των κλήσεων που απαντάει ένας οχτάωρος μέσα στο μήνα.

Ενδεικτικά, εάν για ένα μήνα π.χ. προβλεφθεί ότι θα έχουμε 30.000 κλήσεις και το ACR του τμήματος είναι 5% αυτό σημαίνει ότι θέλουμε να απαντηθούν 28.500 κλήσεις. Έστω επίσης ότι ο μέσος χρόνος διαχείρισης είναι 6 λεπτά (360 sec), ο μήνας έχει 22 εργάσιμες μέρες και το shrinkage είναι 22%. Αυτό σημαίνει ότι οι «καθαρές» εργάσιμες μέρες του κάθε υπαλλήλου είναι 17,2. Μια οχτάωρη βάρδια αντιστοιχεί σε 480 λεπτά (Total min/FTE). Επειδή το ACR είναι 5%, η παραγωγικότητα έχει την τιμή 65%. Αυτομάτως, αυτό σημαίνει ότι τα παραγωγικά λεπτά μιας βάρδιας ενός οχτάωρου εργαζόμενου είναι $480 \cdot 0,65 = 313$ λεπτά, δηλαδή 18.780 δευτερόλεπτα. Διαιρώντας το με τα 360 sec που χρειάζεται κατά μέσο όρο για τη διαχείριση της κάθε κλήσης προκύπτει ότι ένας οχτάωρος εργαζόμενος απαντά κατά μέσο όρο 53,2 κλήσεις τη μέρα και θα απαντήσει συνολικά 915 κλήσεις το συγκεκριμένο μήνα. Τέλος, διαιρώντας τον αριθμό των κλήσεων που προβλέφθηκε ότι θα απαντηθούν στο τηλεφωνικό κέντρο με τον αριθμό των κλήσεων που απαντά ένας οχτάωρος υπάλληλος, προκύπτει ότι χρειαζόμαστε 31,2 οχτάωρους εργαζόμενους. Επιπρόσθετα, λαμβάνοντας υπόψιν το κόστος κάθε υπαλλήλου για την εταιρία, έχουμε μια καλή εκτίμηση για το χρηματικό ποσό που θα χρειαστεί το τμήμα. Παρακάτω είναι ο πίνακας για το συγκεκριμένο παράδειγμα:

ΠΙΝΑΚΑΣ 2 ΕΝΔΕΙΚΤΙΚΟΣ ΣΧΕΔΙΑΣΜΟΣ ΓΙΑ ΕΝΑ ΜΗΝΑ

		Month 1
Calls	Calls	30000
	Answered	28500
	AHT	360
	ACR	5%
Shrinkage	Planning shrinkage	22%
KPIs	Working Days	22
	Working days	17,2
	Monthly Calls per FTE	915
	Total min/FTE	480
	Productivity	65%
	Productive min	313
	Productive sec	18780
	Calls	53,2
	Manpower demands	31,2

II. Βραχυπρόθεσμη κατανομή εργαζομένων: Αφού έχει γίνει ο υπολογισμός των ατόμων που χρειάζονται για να καλύψουν τον αριθμό των κλήσεων που υπολογίστηκε για τον κάθε μήνα, πρέπει να γίνει η κατανομή των εργαζομένων κατά τη διάρκεια της μέρας (συνήθως για το διάστημα δύο εβδομάδων). Οι εργαζόμενοι στη συγκεκριμένη περίπτωση είναι οχτάωροι, εξάωροι ή πεντάωροι. Έτσι ακολουθείται η παρακάτω διαδικασία:

Το πρώτο βήμα είναι να ερευνηθεί το πώς θα κυμαίνονται οι κλήσεις μέσα στη μέρα. Έτσι, γίνεται η πρόβλεψη της ποσοστιαίας διακύμανσης των κλήσεων μέσα στη μέρα με βάση τις προηγούμενες αντίστοιχες μέρες. Π.χ. Αν θέλουν να υπολογίσουν πώς θα κυμανθούν οι κλήσεις την ερχόμενη Δευτέρα θα πρέπει να υπολογισθεί η διακύμανσή τους τις προηγούμενες Δευτέρες (εξαιρώντας αυτές που μπορεί να ήταν αργίες). Επειδή στο συγκεκριμένο τηλεφωνικό κέντρο κάποιες εισερχόμενες κλήσεις απαιτούν να γίνει και εξερχόμενη κλήση προς τον πελάτη από τον υπάλληλο, γίνεται ο υπολογισμός των συνολικών κλήσεων που θα πραγματοποιηθούν μέσα στη μέρα. Στατιστικά, στα τεχνικά τμήματα παρατηρείται ότι το 35% – 45% των εισερχόμενων κλήσεων απαιτούν και εξερχόμενη κλήση, οπότε προστίθενται οι εξερχόμενες κλήσεις που υπολογίσθηκαν ότι θα πραγματοποιηθούν και βγαίνει ο συνολικός αριθμός των κλήσεων (εισερχόμενες και εξερχόμενες) για κάθε μέρα. Στη συνέχεια κατανέμονται οι κλήσεις μέσα στη μέρα, βάση της διακύμανσης που έχει υπολογισθεί. Επειδή ο στόχος είναι να απαντηθεί το 95% των κλήσεων που θα δεχτεί το τηλεφωνικό κέντρο (ACR 5%), προκύπτει η τελική διακύμανση των κλήσεων που χρειάζεται να πραγματοποιηθούν. Τέλος, βάσει του Productivity (στη συγκεκριμένη περίπτωση είναι 65%), υπολογίζεται ο αριθμός των κλήσεων που θα απαντήσει ο εργαζόμενος ανά ώρα (στη συγκεκριμένη περίπτωση είναι 7). Έτσι, διαιρώντας τον αριθμό των

κλήσεων με αυτόν που μπορεί να απαντήσει ο καθένας, βρίσκουμε πόσα άτομα χρειάζονται κάθε ώρα ώστε να απαντηθούν όλες οι κλήσεις.

Το επόμενο βήμα είναι η κατάλληλη κατανομή των εργαζομένων μέσα στη μέρα, ώστε να μην υπάρχουν μεγάλες ελλείψεις ανά ώρα, αλλά ούτε και να υπάρχει πλεονασμός. Ο τρόπος κατανομής τους γίνεται με εμπειρικό τρόπο και δοκιμές. Λόγω του ότι το κέντρο λειτουργεί 7:30 – 23:30, στην πρώτη και την τελευταία βάρδια (7:30 – 15:30 και 15:30 – 23:30) τοποθετούνται οχτάωροι υπάλληλοι και ανάλογα με τις ανάγκες για τις επόμενες ώρες γίνονται δοκιμές προκειμένου να βρεθεί η βέλτιστη λύση. Η παραπάνω διαδικασία γίνεται για κάθε βδομάδα, ξεκινώντας από την Κυριακή και το Σάββατο καθώς ο αριθμός των κλήσεων είναι λιγότερος από αυτόν μιας καθημερινής μέρας. Ο λόγος που γίνεται με την παραπάνω σειρά είναι για να υπολογισθούν πόσοι εργαζόμενοι θα πάρουν ρεπό το Σαββατοκύριακο και τα ρεπό αυτών που θα δουλέψουν κατανέμονται μέσα στην εβδομάδα.

Τέλος, αφού έχει γίνει η κατανομή τους, ορίζονται τα διαλλείματα που θα έχει ο κάθε εργαζόμενος μέσα στη βάρδια. Ο τρόπος που γίνεται είναι εμπειρικά και προσπαθώντας να μην συμπίπτουν όλα τα διαλλείματα μαζί.



ΕΙΚΟΝΑ 14 AGENT DISTRIBUTION CHART FLOW

4 Προτεινόμενη Μεθοδολογία Πρόβλεψης και Στελέχωσης

4.1 Προτεινόμενη Μεθοδολογία Πρόβλεψης Εισερχομένων Κλήσεων

Στην παρούσα διπλωματική εργασία χρησιμοποιήσαμε τη μέθοδο των νευρωνικών δικτύων για την πρόβλεψη της κίνησης και συγκεκριμένα το μοντέλο LSTM (long sort – term memory). Επειδή τα δεδομένα είναι από 1/1/2014 έως 31/12/2016 δεν υπήρχε η δυνατότητα να δοκιμαστεί σε μηνιαία κλίμακα και χρησιμοποιήθηκε για ημερήσια πρόβλεψη για τους μήνες Οκτώβρη και Νοέμβρη του 2016. Υλοποιήθηκε σε python.

Το πρώτο βήμα ήταν να «φορτωθούν» οι βιβλιοθήκες pandas, sklearn, keras, math, matplotlib και numpy που χρειάζεται για την επεξεργασία των δεδομένων και την εξαγωγή των αποτελεσμάτων.

Από την βιβλιοθήκη pandas χρησιμοποιήθηκαν τα εξής:

- Το DataFrame που είναι ένας τρόπος αποθήκευσης δεδομένων σε ορθογώνιους πίνακες όπου είναι εύκολο να γίνει επισκόπηση. Κάθε σειρά αντιστοιχεί στην τιμή της μεταβλητής και κάθε στήλη περιέχει δεδομένα για συγκεκριμένα δεδομένα.
- Το Series που χρησιμοποιείται ως ένας μονοδιάστατος πίνακας, ικανός να διατηρεί δεδομένα κάθε τύπου.
- Το concat που κάνει μια αλληλουχία διεργασιών στις στήλες των δεδομένων και συνδέει τα δεδομένα των κελιών μεταξύ των στηλών.
- Το read csv που είναι απαραίτητο για να διαβάσει το αρχείο με τα δεδομένα που είναι σε μορφή csv.
- Καθώς τα δεδομένα αντιστοιχούν σε ημερολογιακές μέρες, η εντολή datetime χρησιμοποιείται καθώς είναι ένα πετυχημένο εργαλείο επεξεργασίας χρονοσειρών.

Από την βιβλιοθήκη sklearn χρησιμοποιήθηκαν τα εξής:

- Το mean_squared_error και sqrt που χρησιμοποιούνται προκειμένου να μπορεί να υπολογίσει το μέσο τετραγωνικό σφάλμα και η τετραγωνική ρίζα αντίστοιχα προκειμένου να βρεθεί η κατάλληλη μεθοδολογία για την πρόβλεψη.
- Το MinMaxScaler που χρησιμοποιείται για να μετατραπούν τα δεδομένα σε κλίμακα από το 0 μέχρι το 1 προκειμένου να μπορεί να γίνει ευκολότερη η επεξεργασία τους.

Από την βιβλιοθήκη keras χρησιμοποιήθηκαν τα εξής:

- Το sequential που επιτρέπει τη δημιουργία μοντέλων επιπέδων για τα περισσότερα προβλήματα. Ο περιορισμός της είναι ότι δεν επιτρέπει τη δημιουργία μοντέλων που μοιράζονται επίπεδα ή έχουν πολλαπλές εισόδους ή εξόδους.
- Το Dense που αντιπροσωπεύει τον πολλαπλασιασμό διανυσμάτων.

- Το LSTM που αφορά την εκπαίδευση του νευρωνικού. Δηλαδή το σύστημα μαθαίνει να ξεχωρίζει τις σχετικές από τις μη σχετικές τιμές των δεδομένων. Η έκφραση Long Short-term Memory αναφέρεται στο ότι το σύστημα είναι ένα μοντέλο για μικρή μνήμη που μπορεί να διαρκέσει για μεγάλο χρονικό διάστημα. Είναι ιδανικό να κατηγοριοποιεί, επεξεργάζεται και να προβλέπει χρονοσειρές με άγνωστες χρονικές καθυστερήσεις και διάρκεια μεταξύ των γεγονότων.

Από τις βιβλιοθήκες `math`, `matplotlib` και `numpy` χρησιμοποιήσαμε αντίστοιχα:

- Την εντολή `pyplot` που χρησιμοποιείται για τη δημιουργία γραφήματος στην εμφάνιση των αποτελεσμάτων.
- Την εντολή `sqrt` που χρησιμοποιείται για τον υπολογισμό τετραγωνικής ρίζας.
- Την εντολή `array` που χρησιμοποιείται για τη χρήση πολυδιάστατων πινάκων.

Επόμενο βήμα είναι η προετοιμασία των δεδομένων προκειμένου να μπορούν να «διαβαστούν» από το σύστημα. Το σύστημα «διαβάζει» εισόδους και έχει ως αποτέλεσμα την έξοδο που βγάζει. Επειδή τα δεδομένα μας είναι σε λίστα, έγινε μετατροπή σε μοτίβα εισόδων – εξόδων. Επίσης, τα δεδομένα παρουσιάζουν αυξητική τάση που πρέπει να αφαιρεθεί. Για αυτό, χρησιμοποιήθηκε συνάρτηση που την αφαιρεί με διαφοροποίηση και επιτρέπει τις τιμές να μετατραπούν σε κλίμακα από -1 έως 1. Ακόμα, γίνεται διαχωρισμός των δεδομένων σε δύο τμήματα. Το ένα αφορά την εκπαίδευση του δικτύου και το δεύτερο αυτό που θα δοκιμαστεί.

Έπειτα, πρέπει να ταιριάζουμε το LSTM μοντέλο στα δεδομένα εκπαίδευσης. Αυτό απαιτεί τα δεδομένα να μετατραπούν από δισδιάστατο πίνακα σε τρισδιάστατο. Ακόμα για τη σχεδίαση του LSTM δικτύου χρησιμοποιούμε δομή με ένα κρυφό επίπεδο με δεδομένα και ένα επίπεδο εξόδου με γραμμική διαφοροποίηση και τρεις τιμές εξόδου. Το δίκτυο χρησιμοποιεί τη συνάρτηση τετραγωνικού μέσου σφάλματος και τον αλγόριθμο ADAM για να το πετύχει.

Επόμενο βήμα είναι το δίκτυο να κάνει την πρόβλεψη. Για το λόγο αυτό χρησιμοποιείται η συνάρτηση `model.predict()`, που και αυτή απαιτεί τα δεδομένα να είναι σε τρισδιάστατο πίνακα. Όλη αυτή η διαδικασία περιλαμβάνεται στη συνάρτηση `forecast_lstm()`. Προκειμένου να αξιολογηθεί το αποτέλεσμα της παραπάνω πρόβλεψης χρησιμοποιείται η συνάρτηση `make_forecasts`. Συγκρίνει τα αποτελέσματα κάθε δοκιμής που έγινε και επιλέγει τον καλύτερο τρόπο πρόβλεψης.

Αφού έχουν γίνει οι προβλέψεις, χρειάζεται να μετατραπούν τα αποτελέσματα σε τιμές ίδιας κλίμακας με την αρχική. Η μετατροπή γίνεται χρησιμοποιώντας το `MinMaxScaler` που παρέχει τη συνάρτηση `inverse_transform()`. Μπορούμε να αντιστρέψουμε τη διαφοροποίηση προσθέτοντας την τιμή της τελευταίας παρατήρησης στην πρώτη τιμή πρόβλεψης και αναπαράγοντάς την στις επόμενες τιμές. Αυτό γίνεται με την συνάρτηση `inverse_difference()` και την `inverse_transform()` που «τρέχουν» για κάθε πρόβλεψη. Επιπρόσθετα, δίνεται η

δυνατότητα υπολογισμού του μέσου τετραγωνικού σφάλματος για κάθε πρόβλεψη και η απεικόνιση των αποτελεσμάτων σε γράφημα μέσω των συναρτήσεων `evaluate_forecasts` και `plot_forecasts`.

Τέλος, ο χρήστης πρέπει να επιλέξει το αρχείο που περιέχει τα δεδομένα, το διάστημα των τελευταίων δεδομένων πάνω στο οποίο θα στηρίζεται το δίκτυο προκειμένου να εκπαιδευτεί και να κάνει την πρόβλεψη (`n_lag`), το διάστημα για το οποίο θέλει να προβλέψει (`n_seq`), το χρονικό διάστημα που θα είναι το `test` (`n_test`) και το πόσες φορές θα εκπαιδευτεί το δίκτυο (`n_epochs`). Επίσης υπάρχουν οι επιλογές `n_batch` που αφορά τις παρτίδες στις οποίες θα γίνεται η εκπαίδευση και πρόβλεψη που στη δικιά μας περίπτωση είναι 1 καθώς τα δεδομένα είναι ξεχωριστά και το `n_neurons` που αφορά τους νευρώνες διασύνδεσης μεταξύ δεδομένων και αποτελεσμάτων που επίσης στη δικιά μας περίπτωση είναι ίσο με 3.

Το νευρωνικό δίκτυο χρησιμοποιήθηκε αρχικά με όλα τα δεδομένα. Αυτό δεν είχε το επιθυμητό αποτέλεσμα (απόκλιση περίπου 15%) καθώς οι τιμές στα Σαββατοκύριακα και τις καθημερινές έχουν ξεχωριστή συμπεριφορά. Διαχωρίζοντας τα δεδομένα σε Σαββατοκύριακο και καθημερινές τα αποτελέσματα βελτιώθηκαν. Τα βέλτιστα αποτελέσματα ήταν όταν απομονώσαμε κάθε μέρα ξεχωριστά. Δηλαδή, φτιάχνοντας ξεχωριστό `dataset` για τις Δευτέρες, Τρίτες, Τετάρτες κλπ..

Παρακάτω παρουσιάζεται ο κώδικας που χρησιμοποιήθηκε:

```
from pandas import DataFrame
from pandas import Series
from pandas import concat
from pandas import read_csv
from pandas import datetime
from sklearn.metrics import mean_squared_error
from sklearn.preprocessing import MinMaxScaler
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from math import sqrt
from matplotlib import pyplot
from numpy import array

# date-time parsing function for loading the dataset
def parser(x):
    return datetime.strptime('190' + x, '%Y-%m')

# convert time series into supervised learning problem
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

# create a differenced series
def difference(dataset, interval=1):
    diff = list()
    for i in range(interval, len(dataset)):
        value = dataset[i] - dataset[i - interval]
        diff.append(value)
    return Series(diff)

# transform series into train and test sets for supervised learning
def prepare_data(series, n_test, n_lag, n_seq):
    # extract raw values
    raw_values = series.values
    # transform data to be stationary
    diff_series = difference(raw_values, 1)
    diff_values = diff_series.values
    diff_values = diff_values.reshape(len(diff_values), 1)
    # rescale values to -1, 1
    scaler = MinMaxScaler(feature_range=(-1, 1))
    scaled_values = scaler.fit_transform(diff_values)
    scaled_values = scaled_values.reshape(len(scaled_values), 1)
    # transform into supervised learning problem X, y
    supervised = series_to_supervised(scaled_values, n_lag, n_seq)
    supervised_values = supervised.values
    # split into train and test sets
    train, test = supervised_values[0:-n_test], supervised_values[-
n_test:]
    return scaler, train, test

# fit an LSTM network to training data
def fit_lstm(train, n_lag, n_seq, n_batch, nb_epoch, n_neurons):
    # reshape training into [samples, timesteps, features]
    X, y = train[:, 0:n_lag], train[:, n_lag:]
    X = X.reshape(X.shape[0], 1, X.shape[1])
    # design network
    model = Sequential()
    model.add(LSTM(n_neurons, batch_input_shape=(n_batch, X.shape[1],
X.shape[2]), stateful=True))
    model.add(Dense(y.shape[1]))
    model.compile(loss='mean_squared_error', optimizer='adam')
    # fit network
    for i in range(nb_epoch):

```



```

        model.fit(X, y, epochs=1, batch_size=n_batch, verbose=2,
shuffle=False)
        # model.reset states()
        return model

# make one forecast with an LSTM,
def forecast_lstm(model, X, n_batch):
    # reshape input pattern to [samples, timesteps, features]
    X = X.reshape(1, 1, len(X))
    # make forecast
    = model.predict(X, batch_size=n_batch)
    # convert to array
    return [x for x in forecast[0, :]]

# evaluate the persistence model
def make_forecasts(model, n_batch, train, test, n_lag, n_seq):
    forecasts = list()
    for i in range(len(test)):
        X, y = test[i, 0:n_lag], test[i, n_lag:]
        # make forecast
        = forecast_lstm(model, X, n_batch)
        # store the forecast
        forecasts.append(forecast)
    return forecasts

# invert differenced forecast
def inverse_difference(last_ob, forecast):
    # invert first forecast
    inverted = list()
    inverted.append(forecast[0] + last_ob)
    # propagate difference forecast using inverted first value
    for i in range(1, len(forecast)):
        inverted.append(forecast[i] + inverted[i - 1])
    return inverted

# inverse data transform on forecasts
def inverse_transform(series, forecasts, scaler, n_test):
    inverted = list()
    for i in range(len(forecasts)):
        # create array from forecast
        forecast = array(forecasts[i])
        forecast = forecast.reshape(1, len(forecast))
        # invert scaling
        inv_scale = scaler.inverse_transform(forecast)
        inv_scale = inv_scale[0, :]
        # invert differencing
        index = len(series) - n_test + i - 1
        last_ob = series.values[index]
        inv_diff = inverse_difference(last_ob, inv_scale)
        # store
        inverted.append(inv_diff)
    return inverted

```

```

# evaluate the RMSE for each forecast time step
def evaluate_forecasts(test, forecasts, n_lag, n_seq):
    for i in range(n_seq):
        actual = [row[i] for row in test]
        predicted = [forecast[i] for forecast in forecasts]
        rmse = sqrt(mean_squared_error(actual, predicted))
        print('t+%d RMSE: %f' % ((i + 1), rmse))

# plot the forecasts in the context of the original dataset
def plot_forecasts(series, forecasts, n_test):
    # plot the entire dataset in blue
    pyplot.plot(series.values)
    # plot the forecasts in red
    for i in range(len(forecasts)):
        off_s = len(series) - n_test + i - 1
        off_e = off_s + len(forecasts[i]) + 1
        xaxis = [x for x in range(off_s, off_e)]
        yaxis = [series.values[off_s]] + forecasts[i]
        pyplot.plot(xaxis, yaxis, color='red')
    # show the plot
    pyplot.show()

# load dataset
series = read_csv('sundays.csv', delimiter=';', usecols=[1],
engine='python')
# configure
n_lag = 1
n_seq = 1
n_test = 5
n_epochs = 500
n_batch = 1
n_neurons = 1
# prepare data
scaler, train, test = prepare_data(series, n_test, n_lag, n_seq)
# fit model
model = fit_lstm(train, n_lag, n_seq, n_batch, n_epochs, n_neurons)
# make forecasts
forecasts = make_forecasts(model, n_batch, train, test, n_lag, n_seq)
# inverse transform forecasts and test
forecasts = inverse_transform(series, forecasts, scaler, n_test + 2)
actual = [row[n_lag:] for row in test]
actual = inverse_transform(series, actual, scaler, n_test + 2)
# evaluate forecasts
evaluate_forecasts(actual, forecasts, n_lag, n_seq)
# plot forecasts
plot_forecasts(series, forecasts, n_test + 2)

print(series)
print(forecasts)

```

4.2 Προτεινόμενη Μεθοδολογία Στελέχωσης Προσωπικού

Λαμβάνοντας υπόψιν τόσο τις μεθόδους που υπάρχουν και τη μέθοδο που χρησιμοποιεί η εταιρία που έγινε η έρευνα, δημιουργήθηκε ένα εργαλείο που αυτοματοποιεί την διαδικασία. Για την κατασκευή του εργαλείου έπρεπε πρώτα να ληφθούν υπόψιν τα ωράρια που μπορεί να εργαστεί ένας 8ωρος, ένας 6ωρος και ένας 5ωρος υπάλληλος. Δηλαδή:

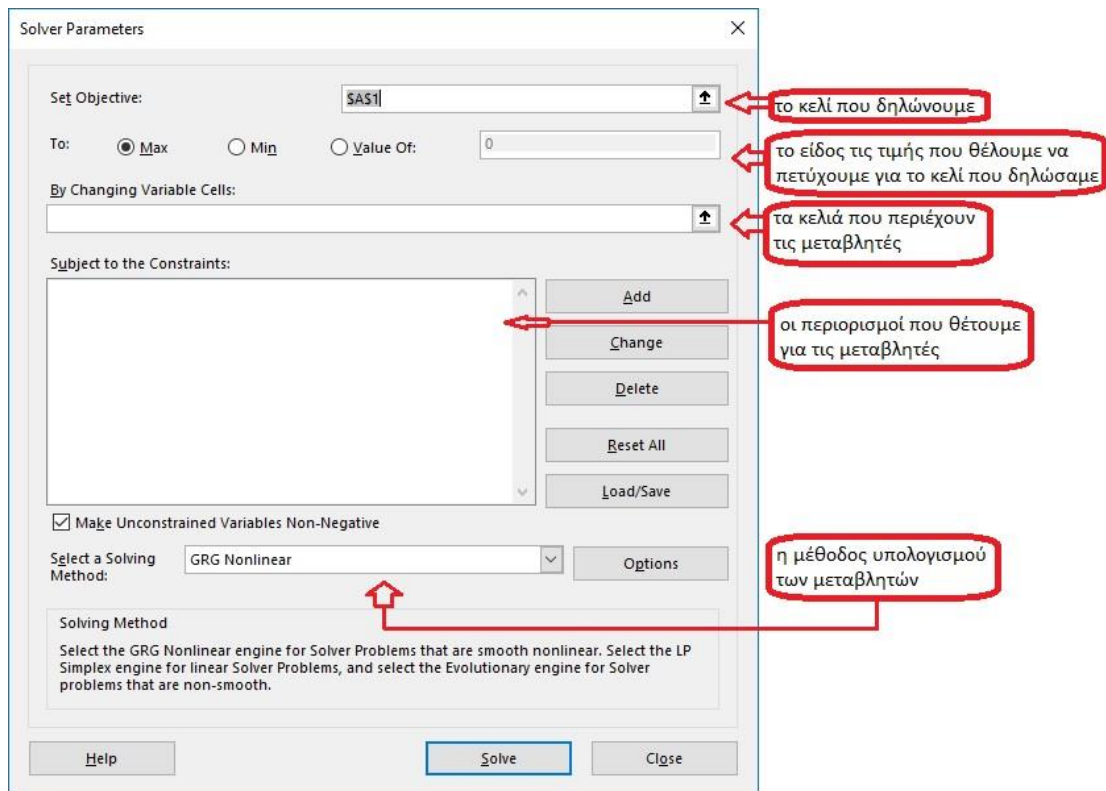
ΠΙΝΑΚΑΣ 3 ΔΥΝΑΤΕΣ ΩΡΕΣ ΕΡΓΑΣΙΑΣ ΚΑΘΕ ΟΧΤΑΩΡΟΥ, ΕΞΑΩΡΟΥ ΚΑΙ ΠΕΝΤΑΩΡΟΥ

οχτάωρος	Εξάωρος	πεντάωρος
7:30 – 15:30	7:30 – 13:30	7:30 – 12:30
8:00 – 16:00	8:00 – 14:00	8:00 – 13:00
9:00 – 17:00	9:00 – 15:00	9:00 – 14:00
10:00 – 18:00	10:00 – 16:00	10:00 – 15:00
11:00 – 19:00	11:00 – 17:00	11:00 – 16:00
12:00 – 20:00	12:00 – 18:00	12:00 – 17:00
13:00 – 21:00	13:00 – 19:00	13:00 – 18:00
14:00 – 22:00	14:00 – 20:00	14:00 – 19:00
15:00 – 23:00	15:00 – 21:00	15:00 – 20:00
15:30 – 23:30	16:00 – 22:00	16:00 – 21:00
	17:00 – 23:00	17:00 – 22:00
	17:30 – 23:30	18:00 – 23:00
		18:30 – 23:30

Στο πρώτο βήμα που αφορά τον υπολογισμό των αναγκών σε εργαζόμενους σε ωριαία κλίμακα, ακολουθήθηκε η μεθοδολογία που αναλύθηκε προηγουμένως καθώς ο μόνος τρόπος υπολογισμού είναι βάσει ιστορικών δεδομένων.

Η κατανομή των υπαλλήλων σε βάρδιες υλοποιήθηκε σε Microsoft Excel, με τη βοήθεια του εργαλείου Solver. Στο συγκεκριμένο εργαλείο, ο χρήστης θέτει τους περιορισμούς στις μεταβλητές μίας εξίσωσης και έχει τη δυνατότητα να υπολογίζει τον κατάλληλο συνδυασμό των μεταβλητών προκειμένου να πετύχει τη μέγιστη, ελάχιστη ή συγκεκριμένη τιμή στο κελί που του δηλώνουμε. Οι μέθοδοι που χρησιμοποιεί είναι GRG Nonlinear, LP Simplex ή Evolutionary. Εάν ο στόχος και οι περιορισμοί είναι γραμμικές συναρτήσεις των μεταβλητών, η καλύτερη μέθοδος είναι η Simplex LP Solving καθώς παρέχει την βέλτιστη λύση γρήγορα, ανάλογα πάντα με το μέγεθος του μοντέλου. Εάν ο στόχος και οι περιορισμοί είναι ομαλές, μη γραμμικές συναρτήσεις των μεταβλητών, δεν μπορεί να επιλυθεί με την παραπάνω μέθοδο και ο χρόνος επίλυσης είναι μεγαλύτερος. Σε αυτές τις περιπτώσεις πρέπει να επιλέξουμε τη μέθοδο GRG Nonlinear. Τέλος, αν ο στόχος και οι περιορισμοί είναι μη ομαλές και μη γραμμικές συναρτήσεις (για παράδειγμα όταν χρησιμοποιούμε τις συναρτήσεις IF, CHOOSE ή LOOKUP που τα επιχειρήματά τους βασίζονται σε μεταβλητές αποφάσεων) χρησιμοποιείται η μέθοδος Evolutionary.

Τα πεδία που συμπληρώνονται είναι τα παρακάτω:



ΕΙΚΟΝΑ 15 SOLVER MENU

Το πρώτο βήμα ήταν η δημιουργία κατάλληλης περιγραφής κάθε δυνατής βάρδιας οχτάωρου, εξάωρου και πεντάωρου με τέτοιο τρόπο ώστε να είναι αναγνωρίσιμο από το σύστημα. Έτσι δημιουργήθηκε πίνακας με 17 στήλες (μία για κάθε ώρα από τις 7:30 έως τις 23:30) και 10 γραμμές για τους οχτάωρους 12 γραμμές για τους εξάωρους και 13 για τους πεντάωρους, δηλαδή όσες και οι δυνατές βάρδιες για οχτάωρους, εξάωρους και πεντάωρους. Σε κάθε γραμμή, στα κελιά που αντιστοιχούν στο ωράριο λειτουργίας τέθηκε η τιμή 1 και στα υπόλοιπα κελιά η τιμή 0 όπως φαίνεται παρακάτω.

	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00
7:30 – 15:30	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0
8:00 – 16:00	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0
9:00 – 17:00	0	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0
10:00 – 18:00	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0
11:00 – 19:00	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	0
12:00 – 20:00	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0
13:00 – 21:00	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0
14:00 – 22:00	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0
15:00 – 23:00	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0
15:30 – 23:30	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1
7:30 – 13:30	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0
8:00 – 14:00	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
9:00 – 15:00	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0
10:00 – 16:00	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0
11:00 – 17:00	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0
12:00 – 18:00	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0
13:00 – 19:00	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0
14:00 – 20:00	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0
15:00 – 21:00	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0
16:00 – 22:00	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0
17:00 – 23:00	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0
17:30 – 23:30	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1
7:30 – 12:30	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
8:00 – 13:00	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0
9:00 – 14:00	0	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
10:00 – 15:00	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0
11:00 – 16:00	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0	0
12:00 – 17:00	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0
13:00 – 18:00	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0
14:00 – 19:00	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0
15:00 – 20:00	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0
16:00 – 21:00	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0
17:00 – 22:00	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0
18:00 – 23:00	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0
18:30 – 23:30	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1

ΕΙΚΟΝΑ 16 ΠΕΡΙΓΡΑΦΗ ΒΑΡΔΙΩΝ ΜΕ 1 ΚΑΙ 0

Έχοντας θέσει τα δυνατά ωράρια κάθε υπαλλήλου, το επόμενο βήμα είναι η αξιοποίηση της πληροφορίας από την πρόβλεψη που έγινε προηγουμένως. Έτσι δημιουργήθηκε ένας δεύτερος πίνακας όπου έχει 17 στήλες, όσες και οι ώρες λειτουργίας, και η κάθε γραμμή αποτελείται από τις πληροφορίες που έχουμε ή χρειαζόμαστε. Έτσι, η πρώτη γραμμή αναφέρεται στις ώρες, η δεύτερη στις κλήσεις που έχουν προβλεφθεί ανά ώρα λειτουργίας, η τρίτη στους εργαζόμενους που χρειάζονται, η τέταρτη στους υπαλλήλους που υπολογίσθηκαν και στις επόμενες τρεις αναφέρονται ο αριθμός των εργαζομένων που υπολογίσθηκαν ότι θα βρίσκονται σε βάρδια κάθε ώρα. Στην τελευταία γραμμή υπολογίζεται η διαφορά ανάμεσα στην ανάγκη σε εργαζόμενους και σε αυτούς που υπολογίσθηκαν. Το ιδανικότερο σενάριο είναι η διαφορά μεταξύ των αναγκών και των εργαζομένων να είναι μηδέν. Αυτό, λόγω του ότι τα ωράρια εργασίας είναι συνεχόμενα και ο αριθμός των κλήσεων που εισέρχονται στο κέντρο δεν είναι ίδιος κάθε ώρα αλλά έχει διακυμάνσεις, δεν είναι εφικτό. Έτσι, στο ρεαλιστικό σενάριο, θα πρέπει η διαφορά μεταξύ των αναγκών και των εργαζομένων ανά ώρα να είναι όσο το δυνατόν πιο κοντά στο μηδέν. Επειδή το εργαλείο Solver δεν έχει τη δυνατότητα να βρει για πολλαπλά κελιά τη μικρότερη δυνατή τιμή, δημιουργήθηκε ένα κελί (SUM) όπου η τιμή του είναι η απόλυτη τιμή του αθροίσματος των παραπάνω διαφορών. Επειδή ο αριθμός των διαθέσιμων εργαζομένων είναι συγκεκριμένος, δημιουργήθηκαν κελιά που δίνουν τη δυνατότητα στο χρήστη να συμπληρώνει τον ελάχιστο (min) και μέγιστο (max) αριθμό των εργαζομένων που θέλει να κατανεμηθούν μέσα στη μέρα. Στην περίπτωση που θέλει να χρησιμοποιηθεί συγκεκριμένος αριθμός (π.χ. οχτάωρων) τοποθετεί τον ίδιο αριθμό στα κελιά min και max.

Εκτελώντας το πρόγραμμα μόνο με τα παραπάνω, παρατηρήθηκε ότι δεν έχουμε τα ικανοποιητικά αποτελέσματα, καθώς το εργαλείο τοποθετεί όλους τους εργαζόμενους τις πρώτες ώρες και αφήνοντας λιγότερους τις επόμενες. Έτσι, ενώ το κελί SUM έχει τιμή κοντά στο μηδέν, ταυτόχρονα έχουμε πλεόνασμα εργαζομένων τις πρώτες ώρες και έλλειμα τις επόμενες με αποτέλεσμα να μην έχουμε τη βέλτιστη παραγωγικότητα και να χάνονται κλήσεις τις ώρες που υπάρχει έλλειμα. Οπότε προέκυψε η ανάγκη για έναν περιορισμό που θα ελέγχει τη διαφορά ανάμεσα στις ανάγκες και στους εργαζόμενους ανά ώρα. Δημιουργήθηκαν δύο πεδία όπου ο χρήστης έχει τη δυνατότητα να θέτει την ελάχιστη (min) και μέγιστη (max) διαφορά μεταξύ των ωριαίων αναγκών σε υπαλλήλους και των εργαζομένων που θα κατανεμηθούν. Σε δοκιμές που πραγματοποιήθηκαν τα αποτελέσματα ήταν εμφανώς βελτιωμένα αλλά υπήρξαν περιπτώσεις που η διακύμανση σε ανάγκες ήταν μεγαλύτερη με αποτέλεσμα να πρέπει να ορισθεί μεγαλύτερο εύρος διαφοράς ανάμεσα σε ανάγκες και εργαζόμενους. Για να καλυφθεί αυτή η ιδιαιτερότητα, δόθηκε η δυνατότητα στο χρήστη να θέτει διαφορετικό εύρος από αυτό που όρισε προηγουμένως σε συγκεκριμένες ώρες που επιθυμεί. Έτσι π.χ. ενώ έχει θέσει ως γενικό περιορισμό η διαφορά να κυμαίνεται μεταξύ -2 και 2 μπορεί να εξαιρέσει το διάστημα 14:00 – 17:00 και να θέσει ως περιορισμό τη διαφορά μεταξύ 0 και 3. Ως

αποτέλεσμα, ο χρήστης έχει μεγαλύτερη ευελιξία στους περιορισμούς που μπορεί να θέσει.

Τέλος, υπάρχουν περιπτώσεις που οι υπάλληλοι ζητούν κάποιες μέρες να έχουν συγκεκριμένο ωράριο. Μόνο με τα παραπάνω δεδομένα το εργαλείο δεν μπορεί να γνωρίζει τις επιθυμίες των εργαζομένων και αυτό δημιούργησε την ανάγκη για έναν ακόμα περιορισμό. Δίπλα σε κάθε δυνατή βάρδια δημιουργήθηκε ένα κελί, όπου ο χρήστης μπορεί να δηλώσει τον ελάχιστο αριθμό εργαζομένων που επιθυμεί από τη συγκεκριμένη κατηγορία. Σε περίπτωση που δεν θέλει αυτόν τον περιορισμό αφήνει κενό το κελί. Δηλαδή αν 3 οχτάωροι του ζητήσουν να δουλέψουν 8:00 – 16:00, ο χρήστης έχει τη δυνατότητα να δεσμεύσει 3 από τους οχτάωρους για αυτό το διάστημα και το εργαλείο να καταναίμει τους υπόλοιπους με το βέλτιστο τρόπο.

Αφού έχουν τεθεί οι κατάλληλοι περιορισμοί, γίνεται εκτέλεση του εργαλείου με Evolutionary μέθοδο καθώς στους περιορισμούς έχουμε συναρτήσεις του τύπου if, choose ή lookup. Στην περίπτωση που οι περιορισμοί και τα δεδομένα δεν καθιστούν δυνατή την εύρεση μιας λύσης, το πρόγραμμα εμφανίζει error και ο χρήστης θα πρέπει να αλλάξει τους περιορισμούς που έχει θέσει. Έχοντας εμφανίσει τα αποτελέσματα, ο χρήστης μπορεί να εκτελέσει εκ νέου το εργαλείο με τη μέθοδο GRG Nonlinear καθώς στις περισσότερες περιπτώσεις βελτιώνει τα αποτελέσματα.

Εκτός της κατανομής των διαθέσιμων υπαλλήλων, δίνει τη δυνατότητα στο χρήστη να υπολογίσει τις ανάγκες σε επιπλέον ανθρώπινο δυναμικό. Εάν ο χρήστης τοποθετήσει τους διαθέσιμους εργαζόμενους στα κελιά min και εκτελέσει το εργαλείο με τους περιορισμούς που θέλει, θα εμφανίσει πόσους ακόμα χρειάζεται για να καλύψει τις ανάγκες. Αυτό είναι πολύ χρήσιμο καθώς στα τηλεφωνικά κέντρα προστίθενται ανά διαστήματα και άλλες υπηρεσίες που εξυπηρετούν οι υπάλληλοι και οι ανάγκες μπορεί να μεταβάλλονται συνεχώς. Επίσης, αν ο χρήστης δεν τοποθετήσει καμία τιμή στα κελιά min και max το εργαλείο θα βρει το βέλτιστο συνδυασμό εργαζομένων για κάθε μέρα.

hours	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Time	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00
Calls																	
Agents needed	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Agents scheduled	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
X (8 hours)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Y (6 hours)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Z (5 hours)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
DIFF	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
SUM	0																
min																	
max																	

Total	Min	Max
0		
0		
0		
0		
	default	

↑
 ωριαία διαφορά μεταξύ αναγκών και εργαζομένων

↑
 πρόβλεψη κλήσεων ανά ώρα

↑
 ελάχιστος και μέγιστος διαθέσιμος αριθμός agent

↑
 προεπιλεγμένη διαφορά μεταξύ αναγκών και εργαζομένων

ΕΙΚΟΝΑ 17 ΕΡΓΑΛΕΙΟ ΚΑΤΑΝΟΜΗΣ ΕΡΓΑΖΟΜΕΝΩΝ (ΜΕΡΟΣ 1)

	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00	Min Value	
	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0		7:30 – 15:30
	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0		8:00 – 16:00
	0	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0		9:00 – 17:00
	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0		10:00 – 18:00
	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	0		11:00 – 19:00
	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0		12:00 – 20:00
	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0		13:00 – 21:00
	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0	0		14:00 – 22:00
	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1	0		15:00 – 23:00
	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	1	1		15:30 – 23:30
	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0		7:30 – 13:30
	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0		8:00 – 14:00
	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0		9:00 – 15:00
	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0		10:00 – 16:00
	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0	0		11:00 – 17:00
	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0	0		12:00 – 18:00
	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0		13:00 – 19:00
	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0		14:00 – 20:00
	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0	0		15:00 – 21:00
	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0	0		16:00 – 22:00
	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1	0		17:00 – 23:00
	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	1		17:30 – 23:30
	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0		7:30 – 12:30
	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0		8:00 – 13:00
	0	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0		9:00 – 14:00
	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0		10:00 – 15:00
	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0	0		11:00 – 16:00
	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0	0		12:00 – 17:00
	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0		13:00 – 18:00
	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0		14:00 – 19:00
	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0		15:00 – 20:00
	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0		16:00 – 21:00
	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0		17:00 – 22:00
	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0		18:00 – 23:00
	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	1	1		18:30 – 23:30

↑
 αριθμός agent ανά
 βάρδια μετά την
 εκτέλεση του εργαλείου

↑
 ο ελάχιστος αριθμός
 εργαζομένων από κάθε
 δυνατό ωράριο που
 θέλει να δεσμεύσει ο
 χρήστης

ΕΙΚΟΝΑ 18 ΕΡΓΑΛΕΙΟ ΚΑΤΑΝΟΜΗΣ ΕΡΓΑΖΟΜΕΝΩΝ (ΜΕΡΟΣ 2)

Η σειρά με την οποία γίνεται η κατανομή των εργαζομένων είναι ίδια με αυτή που αναφέρθηκε στο τμήμα που έγινε η έρευνα. Έτσι υπολογίζονται πρώτα οι Κυριακές και τα Σάββατα που έχουν λιγότερες κλήσεις και μετά οι καθημερινές ώστε να κατανεμηθούν με βέλτιστο τρόπο τα ρεπό και οι βάρδιες του κάθε εργαζόμενου.

Το επόμενο βήμα είναι ο καθορισμός των διαλλειμάτων του κάθε υπαλλήλου. Τα διαλλείματα στη συγκεκριμένη περίπτωση είναι τρία (δύο των 15 λεπτών και ένα των 30 λεπτών). Υλοποιήθηκε με την ίδια λογική με τα παραπάνω και έχοντας πλέον ως δεδομένο τον αριθμό των εργαζόμενων ανά ώρα. Έτσι, η κάθε ώρα χωρίστηκε σε τέσσερα τμήματα των 15 λεπτών, θεωρώντας ότι οι κλήσεις μέσα στην ώρα κατανέμονται ισόποσα. Επίσης, σε κάθε δυνατή βάρδια ορίστηκαν πέντε διαφορετικές επιλογές για διαλλείματα. Οι επιλογές έγιναν με γνώμονα τα παρακάτω:

- Το πρώτο διάλλειμα του κάθε εργαζόμενου να γίνεται μετά την πρώτη ώρα εργασίας καθώς σε αυτήν είναι πιο παραγωγικός.
- Τα διαλλείματα να έχουν διάστημα περίπου 90 λεπτών μεταξύ τους.
- Τα δεκαπεντάλεπτα διαλλείματα κάθε βάρδιας να μην συμπίπτουν μεταξύ τους.
- Το διάλλειμα της μισής ώρας τοποθετήθηκε είτε μεσημεριανές είτε βραδινές ώρες όπου οι κλήσεις στο κέντρο είναι λιγότερες και δίνουν τη δυνατότητα στον εργαζόμενο να φάει.

Π.χ. για την πρώτη βάρδια ενός οχτάωρου (7:30 – 15:30) δημιουργήθηκαν οι εξής επιλογές διαλλειμάτων:

- 8:45 – 9:00 , 10:45 – 11:00 και 12:45 – 13:15
- 9:00 – 9:15, 11:00 – 11:15 και 13:00 – 13:30
- 9:15 – 9:30, 11:15 – 11:30 και 13:15 – 13:45
- 9:30 – 9:45, 11:30 – 11:45 και 13:30 – 14:00
- 9:45 – 10:00, 11:45 – 12:00 και 13:45 – 14:15

Ομοίως και για τις υπόλοιπες βάρδιες οχτάωρου, εξάωρου και πεντάωρου.

Ο αριθμός των υπαλλήλων ανά βάρδια επιλέγεται αυτόματα βάσει των προηγούμενων αποτελεσμάτων. Έτσι, το μόνο που έχει να κάνει ο χρήστης είναι να εκτελέσει το πρόγραμμα με τη μέθοδο GRG Nonlinear.

Η εικόνα του εργαλείου αποτυπώνεται στις παρακάτω εικόνες:

Λόγω του ότι η εικόνα είναι πολύ μεγάλη και δεν είναι ευδιάκριτη, παρακάτω παρουσιάζεται ενδεικτικά πώς είναι για την πρώτη βάρδια οχτάωρου:

Time	7:30	7:45	8:00	8:15	8:30	8:45	9:00	9:15	9:30	9:45	10:00	10:15	10:30	10:45	11:00	11:15	11:30	11:45	12:00	12:15	12:30	12:45	13:00	13:15	13:30	13:45	14:00	14:15	14:30	14:45	15:00	15:15			
Calls																																			
Agents needed																																			
Agents scheduled																																			
X (8 hours)																																			
Y (6 hours)																																			
Z (5 hours)																																			
DIFF																																			
time	Agents	breaks	7:30	7:45	8:00	8:15	8:30	8:45	9:00	9:15	9:30	9:45	10:00	10:15	10:30	10:45	11:00	11:15	11:30	11:45	12:00	12:15	12:30	12:45	13:00	13:15	13:30	13:45	14:00	14:15	14:30	14:45	15:00	15:15	
7:30 - 15:30			1	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	0	1	1	1	1	1	1	1	1	1	
			1	1	1	1	1	0	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	0	1	1	1	1	1	1	1	1	
			1	1	1	1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	0	0	1	1	1	1	1	1	1	
			1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	0	0	1	1	1	1	1	1

ΕΙΚΟΝΑ 22 ΠΙΘΑΝΑ ΔΙΑΛΛΕΙΜΑΤΑ ΤΗΣ ΠΡΩΤΗΣ ΒΑΡΔΙΑΣ ΕΝΟΣ ΟΧΤΑΩΡΟΥ

Ομοίως και για τις υπόλοιπες βάρδιες, με κόκκινο χαρακτηρίζονται τα διαλλείματα και με άσπρο τα χρονικά τμήματα που εργάζεται ο εργαζόμενος και με μαύρο οι ώρες εκτός εργασίας. Το πεδίο Agents δίπλα στο ωράριο συμπληρώνεται αυτόματα με βάση τα αποτελέσματα από την προηγούμενη διεργασία και στα διπλανά πεδία (breaks) αναγράφεται ο αριθμός των υπαλλήλων που θα έχουν τα αντίστοιχα διαλλείματα.

4.3 Πιλοτική Λειτουργία μέσω Προσομοιώσεων

4.3.1 Δεδομένα Προσομοίωσης

Προκειμένου να αποφανθούμε για την αποτελεσματικότητα του εργαλείου έγινε δοκιμή για το διάστημα 3 Οκτώβρη έως 27 Νοέμβρη του 2016. Τα διαθέσιμα δεδομένα ήταν:

- Ο διαθέσιμος αριθμός εργαζομένων το παραπάνω διάστημα (80 οχτάωροι, 18 εξάωροι και 10 πεντάωροι)
- Οι μέρες αδειών του κάθε εργαζόμενου εκείνο το χρονικό διάστημα
- Το ωράριο λειτουργίας του τμήματος
- Ο αριθμός των κλήσεων που προβλέφθηκαν ανά ημέρα
- Η ποσοστιαία διακύμανση των κλήσεων μέσα στη μέρα

4.3.2 Εφαρμογή και Αποτελέσματα

Ξεκινώντας από την πρώτη εβδομάδα 3/10/2016 – 9/10/2016 η κατανομή των κλήσεων βάσει ιστορικότητας είναι η εξής:

Calls distribution							
	3-Οκτ	4-Οκτ	5-Οκτ	6-Οκτ	7-Οκτ	8-Οκτ	9-Οκτ
	Δευ	Τρι	Τετ	Πεμ	Παρ	Σαβ	Κυρ
07:00	0,5%	0,5%	0,5%	0,4%	0,7%	0,5%	0,1%
08:00	2,6%	3,7%	2,6%	2,9%	2,7%	2,8%	2,4%
09:00	5,9%	6,2%	6,4%	6,4%	5,6%	6,8%	5,4%
10:00	7,8%	8,0%	6,3%	7,1%	5,7%	8,2%	7,5%
11:00	7,9%	7,2%	9,1%	7,9%	7,1%	9,2%	7,6%
12:00	7,3%	6,0%	6,5%	7,8%	6,3%	9,6%	7,9%
13:00	7,4%	7,1%	7,8%	7,8%	6,3%	10,0%	7,6%
14:00	6,8%	7,6%	8,0%	7,7%	6,3%	8,3%	6,1%
15:00	6,3%	7,4%	6,6%	6,2%	9,9%	7,2%	5,0%
16:00	7,0%	7,3%	6,6%	6,4%	7,5%	5,8%	5,3%
17:00	5,9%	7,2%	7,1%	6,8%	5,9%	6,7%	5,8%
18:00	6,8%	7,0%	7,1%	7,6%	7,1%	5,8%	7,3%
19:00	7,8%	6,8%	6,9%	6,9%	7,8%	5,9%	7,9%
20:00	7,8%	6,9%	7,0%	6,6%	7,7%	4,9%	8,1%
21:00	6,8%	5,9%	5,8%	6,0%	7,4%	3,7%	8,0%
22:00	3,5%	3,9%	4,1%	3,8%	3,9%	3,1%	5,5%
23:00	1,9%	1,4%	1,7%	1,6%	2,0%	1,5%	2,6%

ΕΙΚΟΝΑ 23 ΠΟΣΟΣΤΙΑΙΑ ΔΙΑΚΥΜΑΝΣΗ ΚΛΗΣΕΩΝ 3/10 - 9/10

Βάσει της πρόβλεψης για τις παραπάνω μέρες στις 3/10 θα έχουμε 3.466 κλήσεις, στις 4/10 3.398, στις 5/10 3.325, στις 6/10 3.361, στις 7/10 3367, στις 8/10 2.833 και στις 9/10 1.596. Υπολογίζοντας ότι το 40% των εισερχόμενων κλήσεων θα χρειαστεί και εξερχόμενη κλήση, το σύνολο των κλήσεων που θα πραγματοποιηθούν είναι στις 3/10 4.853 κλήσεις, στις 4/10 4.758 κλήσεις, στις 5/10

4.655 κλήσεις, στις 6/10 4.706 κλήσεις, στις 7/10 4.714 κλήσεις, στις 8/10 3.967 κλήσεις και στις 9/10 2.235 κλήσεις όπως αποτυπώνεται στον παρακάτω πίνακα:

Incoming / Outgoing calls							
Forecast	3-Οκτ	4-Οκτ	5-Οκτ	6-Οκτ	7-Οκτ	8-Οκτ	9-Οκτ
Incoming calls	3466	3398	3325	3361	3367	2833	1596
Outgoing calls	1387	1360	1330	1345	1347	1134	639
Sum	4853	4758	4655	4706	4714	3967	2235

ΕΙΚΟΝΑ 24 ΑΡΙΘΜΟΣ ΚΛΗΣΕΩΝ ΠΟΥ ΘΑ ΠΡΑΓΜΑΤΟΠΟΙΗΘΟΥΝ ΣΤΟ ΤΗΛΕΦΩΝΙΚΟ ΚΕΝΤΡΟ

Πολλαπλασιάζοντας τα ποσοστά που αναφέρθηκαν προηγουμένως με το σύνολο των κλήσεων κάθε μέρας, έχουμε τα παρακάτω αποτελέσματα:

	3-Οκτ	4-Οκτ	5-Οκτ	6-Οκτ	7-Οκτ	8-Οκτ	9-Οκτ
	Δευ	Τρι	Τετ	Πεμ	Παρ	Σαβ	Κυρ
07:00	25	24	22	20	34	20	1
08:00	125	176	123	137	129	109	53
09:00	287	295	298	301	265	272	120
10:00	377	381	294	336	269	326	167
11:00	384	343	423	372	333	364	169
12:00	356	284	301	367	298	379	176
13:00	360	337	361	365	297	396	171
14:00	328	361	374	364	295	330	136
15:00	307	350	305	290	469	284	112
16:00	342	346	305	302	354	230	119
17:00	287	342	329	322	279	266	129
18:00	328	333	330	358	335	230	162
19:00	377	322	322	323	368	234	176
20:00	379	328	328	311	363	196	182
21:00	330	280	272	281	349	148	178
22:00	172	188	190	181	185	122	123
23:00	91	67	77	74	94	60	59
Sum	4855	4757	4654	4704	4716	3966	2233

ΕΙΚΟΝΑ 25 ΚΑΤΑΝΟΜΗ ΚΛΗΣΕΩΝ ΜΕΣΑ ΣΤΗ ΜΕΡΑ

Επειδή όπως αναφέρθηκε στη μεθοδολογία το επιθυμητό είναι να πραγματοποιηθεί το 95% των κλήσεων (ACR 5%), προκύπτει ο πίνακας με τις τελικές τιμές των κλήσεων ανά ώρα:

Answered calls with ACR							
	Δευ	Τρι	Τετ	Πεμ	Παρ	Σαβ	Κυρ
07:00	23	22	20	18	31	18	1
08:00	114	161	113	126	118	100	49
09:00	263	270	273	275	242	249	110
10:00	345	348	269	307	246	299	152
11:00	351	314	387	341	305	333	155
12:00	325	260	275	336	273	347	161
13:00	329	309	330	334	272	363	156
14:00	300	331	342	333	270	302	124
15:00	281	320	279	265	429	260	103
16:00	313	316	279	277	324	210	109
17:00	263	313	301	295	255	243	118
18:00	300	305	302	328	306	210	149
19:00	345	295	295	296	337	214	161
20:00	347	300	300	284	332	179	167
21:00	302	256	249	258	319	136	163
22:00	158	172	174	165	169	111	113
23:00	83	61	70	68	86	55	54
Sum	4440	4354	4259	4306	4313	3630	2045

ΕΙΚΟΝΑ 26 ΚΑΤΑΝΟΜΗ ΚΛΗΣΕΩΝ ΠΟΥ ΘΕΛΩ ΝΑ ΑΠΑΝΤΗΘΟΥΝ ΜΕΣΑ ΣΤΗ ΜΕΡΑ

Έχοντας τα παραπάνω, το επόμενο βήμα είναι η κατανομή των υπαλλήλων. Ξεκινώντας από την Κυριακή, οι διαθέσιμοι εργαζόμενοι είναι 77 οχτάωροι, 17 εξάωροι και 9 πεντάωροι που τοποθετούνται στο κελί max. Στην πρώτη βάρδια έχει υπολογισθεί ότι χρειάζεται ένας υπάλληλος για να καλύψει τις ανάγκες του κέντρου, αλλά προκειμένου να μην βρεθούμε εκτός απροόπτου θέτουμε ως περιορισμό ότι στο διάστημα 7:30 – 8:00 θέλουμε τουλάχιστον δύο. Επίσης, λόγω του ότι το σύνολο των ωρών είναι 16 ώρες, θέσαμε ώστε να έχουμε τουλάχιστον δύο οχτάωρους στη βάρδια 7:30 – 15:30 και δύο οχτάωρους στη βάρδια 15:30 – 23:30. Η απόκλιση ανάμεσα σε ανάγκες και εργαζόμενους θέσαμε να είναι μεταξύ - 1 και 3. Εκτελώντας το πρόγραμμα έχουμε τα παρακάτω αποτελέσματα:

ΠΙΝΑΚΑΣ 4 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 9/10

Ωράριο	agents	Ωράριο	agents	Ωράριο	Agents
7:30 – 15:30	2	7:30 – 13:30	0	7:30 – 12:30	0
8:00 – 16:00	6	8:00 – 14:00	2	8:00 – 13:00	0
9:00 – 17:00	9	9:00 – 15:00	0	9:00 – 14:00	0
10:00 – 18:00	3	10:00 – 16:00	0	10:00 – 15:00	0
11:00 – 19:00	0	11:00 – 17:00	0	11:00 – 16:00	0
12:00 – 20:00	0	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	0	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	0	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	0	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	5	16:00 – 22:00	0	16:00 – 21:00	0
		17:00 – 23:00	8	17:00 – 22:00	3
		17:30 – 23:30	7	18:00 – 23:00	0
				18:30 – 23:30	0
Σύνολο οχτάωρων	25	Σύνολο εξάωρων	17	Σύνολο πεντάωρων	3

Για το Σάββατο, οι διαθέσιμοι υπάλληλοι είναι 77 οχτάωροι, 17 εξάωροι και 9 πεντάωροι που τοποθετούνται στο κελί max. Η απόκλιση ανάμεσα σε ανάγκες και εργαζόμενους θέσαμε να είναι μεταξύ -2 και 3. Ακόμα, δεσμεύτηκαν δύο οχτάωροι στη βάρδια 7:30 – 15:30 και δύο στη βάρδια 15:30 – 23:30. Εκτελώντας το πρόγραμμα έχουμε τα παρακάτω αποτελέσματα:

ΠΙΝΑΚΑΣ 5 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 8/10

Ωράριο	agents	Ωράριο	agents	Ωράριο	agents
7:30 – 15:30	5	7:30 – 13:30	0	7:30 – 12:30	0
8:00 – 16:00	11	8:00 – 14:00	0	8:00 – 13:00	2
9:00 – 17:00	0	9:00 – 15:00	14	9:00 – 14:00	7
10:00 – 18:00	7	10:00 – 16:00	0	10:00 – 15:00	0
11:00 – 19:00	0	11:00 – 17:00	0	11:00 – 16:00	0
12:00 – 20:00	2	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	8	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	0	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	8	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	8	16:00 – 22:00	0	16:00 – 21:00	0
		17:00 – 23:00	3	17:00 – 22:00	0
		17:30 – 23:30	0	18:00 – 23:00	0
				18:30 – 23:30	0
Σύνολο Οχτάωρων	49	Σύνολο εξάωρων	17	Σύνολο πεντάωρων	9

Οι εργαζόμενοι που θα δουλέψουν το Σαββατοκύριακο θα πρέπει να πάρουν τα ρεπό που τους αναλογούν στις υπόλοιπες πέντε μέρες. Αυτό σημαίνει ότι θα πρέπει να μοιραστούν 74 ρεπό οχτάωρων, 34 ρεπό εξάωρων και 12 ρεπό πεντάωρων. Αυτά κατανεμήθηκαν μέσα στην εβδομάδα και έτσι για τη Δευτέρα προκύπτουν 61 διαθέσιμοι οχτάωροι 12 εξάωροι και 7 πεντάωροι. Για την Τρίτη προκύπτουν 63 διαθέσιμοι οχτάωροι 11 εξάωροι και 7 πεντάωροι. Για την Τετάρτη προκύπτουν 61 διαθέσιμοι οχτάωροι 11 εξάωροι και 5 πεντάωροι. Για την Πέμπτη προκύπτουν 63 διαθέσιμοι οχτάωροι 11 εξάωροι και 7 πεντάωροι. Για την Παρασκευή προκύπτουν 61 διαθέσιμοι οχτάωροι 11 εξάωροι και 6 πεντάωροι.

Ακολουθώντας την ίδια μεθοδολογία για τις καθημερινές η κατανομή έχει ως εξής:

ΠΙΝΑΚΑΣ 6 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 3/10

Ωράριο	agents	Ωράριο	agents	Ωράριο	agents
7:30 – 15:30	6	7:30 – 13:30	0	7:30 – 12:30	0
8:00 – 16:00	20	8:00 – 14:00	0	8:00 – 13:00	0
9:00 – 17:00	0	9:00 – 15:00	7	9:00 – 14:00	7
10:00 – 18:00	0	10:00 – 16:00	0	10:00 – 15:00	0
11:00 – 19:00	0	11:00 – 17:00	0	11:00 – 16:00	0
12:00 – 20:00	0	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	0	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	19	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	0	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	16	16:00 – 22:00	5	16:00 – 21:00	0
		17:00 – 23:00	0	17:00 – 22:00	0
		17:30 – 23:30	0	18:00 – 23:00	0
				18:30 – 23:30	0
Σύνολο Οχτάωρων	61	Σύνολο εξάωρων	12	Σύνολο πεντάωρων	7

ΠΙΝΑΚΑΣ 7 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 4/10

Ωράριο	agents	Ωράριο	Agents	Ωράριο	agents
7:30 – 15:30	4	7:30 – 13:30	0	7:30 – 12:30	0
8:00 – 16:00	26	8:00 – 14:00	0	8:00 – 13:00	0
9:00 – 17:00	2	9:00 – 15:00	11	9:00 – 14:00	0
10:00 – 18:00	0	10:00 – 16:00	0	10:00 – 15:00	0
11:00 – 19:00	0	11:00 – 17:00	0	11:00 – 16:00	0
12:00 – 20:00	1	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	0	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	0	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	24	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	6	16:00 – 22:00	0	16:00 – 21:00	7
		17:00 – 23:00	0	17:00 – 22:00	0
		17:30 – 23:30	0	18:00 – 23:00	0
				18:30 – 23:30	0
Σύνολο Οχτάωρων	63	Σύνολο εξάωρων	11	Σύνολο πεντάωρων	7

ΠΙΝΑΚΑΣ 8 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 5/10

Ωράριο	agents	Ωράριο	agents	Ωράριο	agents
7:30 – 15:30	5	7:30 – 13:30	0	7:30 – 12:30	0
8:00 – 16:00	17	8:00 – 14:00	0	8:00 – 13:00	0
9:00 – 17:00	0	9:00 – 15:00	11	9:00 – 14:00	0
10:00 – 18:00	6	10:00 – 16:00	0	10:00 – 15:00	3
11:00 – 19:00	1	11:00 – 17:00	0	11:00 – 16:00	2
12:00 – 20:00	0	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	2	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	0	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	17	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	13	16:00 – 22:00	0	16:00 – 21:00	0
		17:00 – 23:00	0	17:00 – 22:00	0
		17:30 – 23:30	0	18:00 – 23:00	0
				18:30 – 23:30	0
Σύνολο Οχτάωρων	61	Σύνολο εξάωρων	11	Σύνολο πεντάωρων	5

ΠΙΝΑΚΑΣ 9 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 6/10

Ωράριο	agents	Ωράριο	Agents	Ωράριο	agents
7:30 – 15:30	6	7:30 – 13:30	0	7:30 – 12:30	0
8:00 – 16:00	17	8:00 – 14:00	0	8:00 – 13:00	0
9:00 – 17:00	0	9:00 – 15:00	11	9:00 – 14:00	0
10:00 – 18:00	0	10:00 – 16:00	0	10:00 – 15:00	6
11:00 – 19:00	3	11:00 – 17:00	0	11:00 – 16:00	0
12:00 – 20:00	0	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	0	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	9	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	13	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	15	16:00 – 22:00	0	16:00 – 21:00	0
		17:00 – 23:00	0	17:00 – 22:00	0
		17:30 – 23:30	0	18:00 – 23:00	1
				18:30 – 23:30	0
Σύνολο Οχτάωρων	63	Σύνολο εξάωρων	11	Σύνολο πεντάωρων	7

ΠΙΝΑΚΑΣ 10 ΚΑΤΑΝΟΜΗ ΕΡΓΑΖΟΜΕΝΩΝ 7/10


Ωράριο	agents	Ωράριο	Agents	Ωράριο	agents
7:30 – 15:30	4	7:30 – 13:30	3	7:30 – 12:30	0
8:00 – 16:00	15	8:00 – 14:00	0	8:00 – 13:00	0
9:00 – 17:00	7	9:00 – 15:00	0	9:00 – 14:00	0
10:00 – 18:00	0	10:00 – 16:00	0	10:00 – 15:00	0
11:00 – 19:00	0	11:00 – 17:00	8	11:00 – 16:00	0
12:00 – 20:00	0	12:00 – 18:00	0	12:00 – 17:00	0
13:00 – 21:00	0	13:00 – 19:00	0	13:00 – 18:00	0
14:00 – 22:00	5	14:00 – 20:00	0	14:00 – 19:00	0
15:00 – 23:00	19	15:00 – 21:00	0	15:00 – 20:00	0
15:30 – 23:30	11	16:00 – 22:00	0	16:00 – 21:00	0
		17:00 – 23:00	0	17:00 – 22:00	6
		17:30 – 23:30	0	18:00 – 23:00	0
				18:30 – 23:30	0
Σύνολο Οχτάωρων	61	Σύνολο εξάωρων	11	Σύνολο πεντάωρων	6

Για κάθε μία από τις μέρες υπολογίσθηκαν μέσω του εργαλείου και τα διαλλείματα για κάθε υπάλληλο με τη μέθοδο που αναφέρθηκε προηγουμένως. Η ίδια μεθοδολογία χρησιμοποιήθηκε και για τις επόμενες εβδομάδες.

Ενδεικτικά, παρακάτω παρατίθενται κάποια γραφήματα όπου αποτυπώνονται οι διαθέσιμοι εργαζόμενοι ανά ώρα μέσα στη μέρα, συγκριτικά με τις αντίστοιχες ανάγκες.

Sunday 09/10/2016


Time	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00
Calls	1	49	110	152	155	161	156	124	103	109	118	149	161	167	163	113	54
Agents needed	1	7	16	22	23	23	23	18	15	16	17	22	23	24	24	17	9
Agents Scheduled	2	10	19	22	22	22	22	20	18	17	19	23	23	23	23	20	12



ΕΙΚΟΝΑ 27 ΑΝΑΓΚΕΣ / ΕΡΓΑΖΟΜΕΝΟΙ 9/10

Saturday 08/10/2016


Time	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00
Calls	18	100	249	299	333	347	363	302	260	210	243	210	214	179	136	111	55
Agents needed	3	15	36	43	48	50	52	44	38	30	35	30	31	26	20	16	10
Agents scheduled	5	18	39	46	46	48	54	47	36	33	36	29	29	27	19	19	8



ΕΙΚΟΝΑ 28 ΑΝΑΓΚΕΣ / ΕΡΓΑΖΟΜΕΝΟΙ 8/10

Tuesday 04/10/2016


Time	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00
Calls	22	161	270	348	314	260	309	331	320	316	313	305	295	300	256	172	61
Agents needed	4	23	39	50	45	38	45	48	46	46	45	44	43	43	37	25	11
Agents scheduled	4	30	43	43	43	44	44	44	53	40	38	38	38	37	30	30	6



ΕΙΚΟΝΑ 29 ΑΝΑΓΚΕΣ / ΕΡΓΑΖΟΜΕΝΟΙ 4/10

Thursday 06/10/2016

Time	7:00	8:00	9:00	10:00	11:00	12:00	13:00	14:00	15:00	16:00	17:00	18:00	19:00	20:00	21:00	22:00	23:00
Calls	18	126	275	307	341	336	334	333	265	277	295	328	296	284	258	165	68
Agents needed	3	18	40	44	49	48	48	48	38	40	43	47	43	41	37	24	12
Agents scheduled	6	23	34	40	43	43	43	52	42	40	40	41	38	38	38	29	15



ΕΙΚΟΝΑ 30 ΑΝΑΓΚΕΣ / ΕΡΓΑΖΟΜΕΝΟΙ 6/10

5 Σύγκριση Υφιστάμενης και Προτεινόμενης Μεθοδολογίας

5.1 Σύγκριση Μεθόδων Πρόβλεψης Εισερχομένων Κλήσεων

Προκειμένου να υπάρχει μια καλύτερη εικόνα στην αποτελεσματικότητα του κάθε μοντέλου έγινε πρόβλεψη ανά δυο βδομάδες με τρεις διαφορετικές μεθόδους για το διάστημα οχτώ εβδομάδων (03/10/2016 – 27/11/2016). Τα δεδομένα που χρησιμοποιήθηκαν είναι ο αριθμός των κλήσεων από 1/1/2014 έως 27/11/2016. Οι μέθοδοι που χρησιμοποιήθηκαν είναι το Naive, από τα στατιστικά μοντέλα το triple exponential smoothing και από τη μηχανική μάθηση το νευρωνικό δίκτυο Long Short Term Memory.

Η μέθοδος Naive επιλέχθηκε καθώς χρησιμοποιείται από πολλά τηλεφωνικά κέντρα λόγω της απλότητας και του χαμηλού κόστους της. Επίσης χρησιμοποιείται στο τηλεφωνικό κέντρο που έγινε το πείραμα. Επειδή η συγκεκριμένη μέθοδος δεν είναι εύκολο να εφαρμοστεί σε μετέπειτα χρονική στιγμή από το διάστημα που αφορά (καθώς λαμβάνονται υπόψιν και οι εξωγενείς παράγοντες που επηρεάζουν τον αριθμό των εισερχόμενων κλήσεων), στηριχτήκαμε στην πρόβλεψη που έγινε από την εταιρία.

Η μέθοδος triple exponential smoothing χρησιμοποιήθηκε καθώς μπορεί να διαχειριστεί το επίπεδο, την τάση και την εποχικότητα των δεδομένων, μπορεί να μοντελοποιηθεί εύκολα και υπάρχει έτοιμος αλγόριθμος στο excel για τη χρήση του.

Τα νευρωνικά δίκτυα έχουν κάνει την εμφάνισή τους τα τελευταία χρόνια και δεν χρησιμοποιούνται ευρέως στην πρόβλεψη κλήσεων σε τηλεφωνικά κέντρα. Επιλέχθηκε η long short term memory μέθοδος καθώς δείχνει ικανότερη από τις υπόλοιπες στη διαχείριση των δεδομένων.

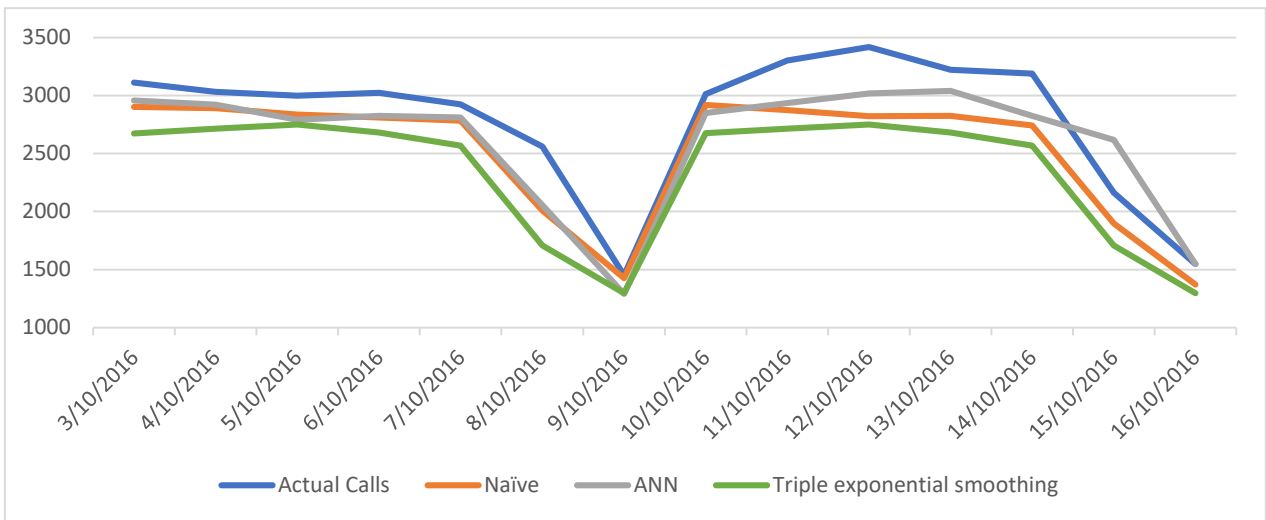
Τα αποτελέσματα της κάθε μεθόδου εμφανίζονται στον πίνακα παρακάτω:

ΠΙΝΑΚΑΣ 11 ΠΙΝΑΚΑΣ ΚΛΗΣΕΩΝ


Date	Actual Calls	Naive	ANN	Triple Exponential Smoothing
Δευτέρα 3/10/2016	3111	2901	2958	2674
Τρίτη 4/10/2016	3033	2891	2920	2713
Τετάρτη 5/10/2016	2998	2836	2792	2749
Πέμπτη 6/10/2016	3023	2810	2825	2681
Παρασκευή 7/10/2016	2923	2784	2811	2567
Σάββατο 8/10/2016	2560	2007	2055	1706
Κυριακή 9/10/2016	1451	1427	1292	1297
Δευτέρα 10/10/2016	3012	2918	2850	2675
Τρίτη 11/10/2016	3303	2875	2935	2713
Τετάρτη 12/10/2016	3419	2822	3017	2749
Πέμπτη 13/10/2016	3222	2825	3039	2681
Παρασκευή 14/10/2016	3188	2743	2825	2568
Σάββατο 15/10/2016	2163	1897	2617	1706

Κυριακή	16/10/2016	1548	1370	1546	1297
Δευτέρα	17/10/2016	3173	2987	3020	2944
Τρίτη	18/10/2016	3456	2944	3288	3074
Τετάρτη	19/10/2016	3042	2890	3358	3186
Πέμπτη	20/10/2016	2907	2831	3132	3136
Παρασκευή	21/10/2016	3271	2776	3086	3009
Σάββατο	22/10/2016	2278	2001	2428	2168
Κυριακή	23/10/2016	1302	1398	1628	1557
Δευτέρα	24/10/2016	3297	3066	3147	2954
Τρίτη	25/10/2016	3263	2993	3481	3083
Τετάρτη	26/10/2016	3253	2905	2963	3195
Πέμπτη	27/10/2016	3161	2899	2845	3145
Παρασκευή	28/10/2016	1529	1806	1465	3019
Σάββατο	29/10/2016	1665	2092	2231	2178
Κυριακή	30/10/2016	1216	1416	1215	1566
Δευτέρα	31/10/2016	3281	3122	3110	2858
Τρίτη	1/11/2016	3084	3081	3213	2930
Τετάρτη	2/11/2016	3377	2991	3135	2853
Πέμπτη	3/11/2016	3285	3003	3044	2756
Παρασκευή	4/11/2016	3113	2917	3134	2368
Σάββατο	5/11/2016	2250	2184	1798	1843
Κυριακή	6/11/2016	1414	1387	1170	1217
Δευτέρα	7/11/2016	3214	3148	3086	2859
Τρίτη	8/11/2016	3181	3111	3030	2931
Τετάρτη	9/11/2016	3658	3021	3360	2854
Πέμπτη	10/11/2016	3607	2949	3233	2757
Παρασκευή	11/11/2016	3264	2919	3026	2369
Σάββατο	12/11/2016	2176	2106	2342	1844
Κυριακή	13/11/2016	1522	1401	1404	1218
Δευτέρα	14/11/2016	3412	3133	3101	3345
Τρίτη	15/11/2016	3215	3096	3168	3324
Τετάρτη	16/11/2016	3416	3005	3815	3457
Πέμπτη	17/11/2016	3534	2962	3723	3327
Παρασκευή	18/11/2016	3292	2931	3215	2951
Σάββατο	19/11/2016	2080	2195	2084	2182
Κυριακή	20/11/2016	1572	1369	1423	1523
Δευτέρα	21/11/2016	3129	3204	3350	3346
Τρίτη	22/11/2016	3094	3135	3093	3326
Τετάρτη	23/11/2016	2990	3073	3343	3458
Πέμπτη	24/11/2016	2745	3024	3346	3328
Παρασκευή	25/11/2016	3002	2939	3206	2952
Σάββατο	26/11/2016	2408	2201	2134	2183
Κυριακή	27/11/2016	3134	1397	1901	1525

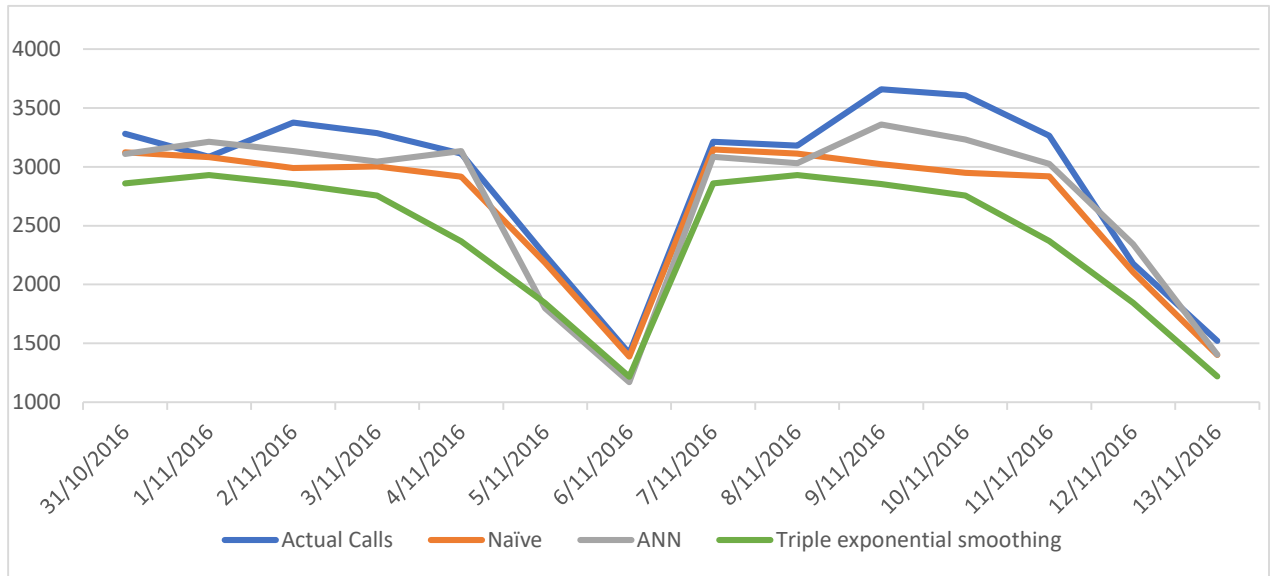
Διαγραμματικά, τα παραπάνω αποτελέσματα έχουν ως εξής:




ΕΙΚΟΝΑ 31 ΔΙΑΓΡΑΜΜΑ ΚΛΗΣΕΩΝ 3/10 – 16/10



ΕΙΚΟΝΑ 32 ΔΙΑΓΡΑΜΜΑ ΚΛΗΣΕΩΝ 17/10 – 30/10



ΕΙΚΟΝΑ 33 ΔΙΑΓΡΑΜΜΑ ΚΛΗΣΕΩΝ 31/10 – 13/11



ΕΙΚΟΝΑ 34 ΔΙΑΓΡΑΜΜΑ ΚΛΗΣΕΩΝ 14/11 – 27/11

Ο παραπάνω πίνακας δίνει μία εκτίμηση για το ποιο μοντέλο έχει καλύτερο αποτέλεσμα κάθε μέρα, αλλά για να είναι πιο ξεκάθαρο χρησιμοποιήθηκε ο δείκτης σφάλματος sMAPE. Η απόκλιση κάθε μοντέλου ανά ημέρα και ανά εβδομάδα, όπως και η συνολική απόκλιση στο διάστημα των οχτώ εβδομάδων παρουσιάζεται στον πίνακα παρακάτω:

ΠΙΝΑΚΑΣ 12 ΣΦΑΛΜΑ sMAPE ΚΑΘΕ ΜΕΘΟΔΟΥ

Date	Naive	ANN	Triple Exponential Smoothing
Δευτέρα 3/10/2016	6,99	5,04	15,11
Τρίτη 4/10/2016	4,79	3,80	11,14
Τετάρτη 5/10/2016	5,55	7,12	8,67
Πέμπτη 6/10/2016	7,30	6,77	11,99
Παρασκευή 7/10/2016	4,87	3,91	12,97
Σάββατο 8/10/2016	24,22	21,89	40,04
Κυριακή 9/10/2016	1,67	11,59	11,21
Εβδομαδιαίος Μέσος όρος	7,91	8,59	15,87
Δευτέρα 10/10/2016	3,17	5,53	11,85
Τρίτη 11/10/2016	13,86	11,80	19,61
Τετάρτη 12/10/2016	19,13	12,49	21,73
Πέμπτη 13/10/2016	13,13	5,85	18,33
Παρασκευή 14/10/2016	15,01	12,07	21,54
Σάββατο 15/10/2016	13,10	19,00	23,62
Κυριακή 16/10/2016	12,20	0,13	17,64
Εβδομαδιαίος Μέσος όρος	12,80	9,55	19,19
Δευτέρα 17/10/2016	6,04	4,94	7,49
Τρίτη 18/10/2016	16,00	4,98	11,70
Τετάρτη 19/10/2016	5,12	9,88	4,62
Πέμπτη 20/10/2016	2,65	7,45	7,58
Παρασκευή 21/10/2016	16,37	5,82	8,34
Σάββατο 22/10/2016	12,95	6,37	4,95
Κυριακή 23/10/2016	7,11	22,25	17,84
Εβδομαδιαίος Μέσος όρος	9,46	8,81	8,93
Δευτέρα 24/10/2016	7,26	4,66	10,97
Τρίτη 25/10/2016	8,63	6,47	5,67
Τετάρτη 26/10/2016	11,30	9,33	1,80
Πέμπτη 27/10/2016	8,65	10,52	0,51
Παρασκευή 28/10/2016	16,61	4,28	65,52
Σάββατο 29/10/2016	22,73	29,06	26,70
Κυριακή 30/10/2016	15,20	0,08	25,16
Εβδομαδιαίος Μέσος όρος	12,91	9,20	19,48
Δευτέρα 31/10/2016	4,97	5,35	13,78
Τρίτη 1/11/2016	0,10	4,10	5,12
Τετάρτη 2/11/2016	12,12	7,43	16,82
Πέμπτη 3/11/2016	8,97	7,62	17,51
Παρασκευή 4/11/2016	6,50	0,67	27,18


Σάββατο	5/11/2016	2,98	22,33	19,89
Κυριακή	6/11/2016	1,93	18,89	14,98
Εβδομαδιαίος Μέσος όρος		5,37	9,48	16,47
Δευτέρα	7/11/2016	2,07	4,06	11,69
Τρίτη	8/11/2016	2,23	4,86	8,18
Τετάρτη	9/11/2016	19,07	8,49	24,69
Πέμπτη	10/11/2016	20,07	10,94	26,71
Παρασκευή	11/11/2016	11,16	7,57	31,78
Σάββατο	12/11/2016	3,27	7,35	16,52
Κυριακή	13/11/2016	8,28	8,07	22,19
Εβδομαδιαίος Μέσος όρος		9,45	7,33	20,25
Δευτέρα	14/11/2016	8,53	9,55	1,98
Τρίτη	15/11/2016	3,77	1,47	3,33
Τετάρτη	16/11/2016	12,80	11,04	1,19
Πέμπτη	17/11/2016	17,61	5,21	6,03
Παρασκευή	18/11/2016	11,60	2,37	10,92
Σάββατο	19/11/2016	5,38	0,19	4,79
Κυριακή	20/11/2016	13,80	9,95	3,17
Εβδομαδιαίος Μέσος όρος		10,50	5,68	4,49
Δευτέρα	21/11/2016	2,37	6,82	6,70
Τρίτη	22/11/2016	1,32	0,03	7,23
Τετάρτη	23/11/2016	2,74	11,15	14,52
Πέμπτη	24/11/2016	9,67	19,73	19,20
Παρασκευή	25/11/2016	2,12	6,57	1,68
Σάββατο	26/11/2016	8,98	12,07	9,80
Κυριακή	27/11/2016	76,67	48,98	69,07
Εβδομαδιαίος Μέσος όρος		14,84	15,05	18,31
Συνολικός μέσος όρος		10,41	9,21	15,37

Όπως φαίνεται παραπάνω, η Naïve μέθοδος και το νευρωνικό δίκτυο έχουν συνολική απόκλιση κοντά στο 10%, ενώ η μέθοδος Triple Exponential Smoothing έχει απόκλιση περίπου 15%. Συγκρίνοντας τα αποτελέσματα σε εβδομαδιαία κλίμακα, μόνο την πρώτη και την πέμπτη εβδομάδα η naïve μέθοδος έχει μικρότερη απόκλιση από το νευρωνικό δίκτυο και η μέθοδος triple exponential smoothing έχει απόκλιση μικρότερη του 10% μόνο την τρίτη και την έβδομη εβδομάδα. Επίσης, εξαιρώντας την τελευταία εβδομάδα, το νευρωνικό δίκτυο έχει πάντα απόκλιση κάτω από 10%, κάτι που το καθιστά πιο σταθερό σε σύγκριση με τα υπόλοιπα. Τέλος, παρατηρώντας αναλυτικότερα τα αποτελέσματα, βλέπουμε ότι κάποιες μέρες όπως το Σάββατο 8/10, 29/10 και την Κυριακή 27/11 οι προβλέψεις σε όλες τις μεθόδους έχουν πολύ μεγάλη απόκλιση από τις πραγματικές τιμές. Αυτό συνέβη καθώς δεν είχαν την ίδια συμπεριφορά με τα προηγούμενα Σάββατα, πιθανότατα λόγω εξωγενών παραγόντων που δεν μπορούσαν να προβλεφθούν.

Χρησιμοποιώντας και τους δείκτες MAPE, MASE καθώς και τη συνάρτηση model fitting φαίνεται ξεκάθαρα ότι η μέθοδος Triple Exponential Smoothing δεν ταιριάζει στα δεδομένα μας.

ΠΙΝΑΚΑΣ 13 ΣΥΓΚΡΙΣΗ ΜΕΘΟΔΩΝ ΜΕ ΣΦΑΛΜΑΤΑ

	MAPE	sMAPE	MASE	MF
Υπολογισμός βάσει ημέρας	8,78%	10,41%	0,47	1,80%
ANN	7,77%	9,21%	0,51	1,21%
Triple Exponential Smoothing	12,52%	15,37%	1,06	3,16%



ΕΙΚΟΝΑ 35 ΣΥΓΚΡΙΤΙΚΟ ΔΙΑΓΡΑΜΜΑ ΜΕΘΟΔΩΝ

Όπως είναι φανερό, το μοντέλο Triple Exponential Smoothing δεν έχει τα επιθυμητά αποτελέσματα σε αντίθεση με τα άλλα δύο μοντέλα. Η Naïve φαίνεται ότι είναι μια αξιόπιστη μέθοδος, αλλά σε αυτό παίζει μεγάλο ρόλο ο ανθρώπινος παράγοντας καθώς η έλλειψη εμπειρίας του χρήστη δεν θα οδηγήσει σε αποτελέσματα όπως τα παραπάνω. Αντιθέτως, το νευρωνικό δίκτυο έχει αξιόπιστα αποτελέσματα καθώς δεν επηρεάζεται από τον ανθρώπινο παράγοντα και είναι γρηγορότερη από την Naïve. Κρίνοντας από τα παραπάνω, η καλύτερη μέθοδος είναι η χρήση ενός νευρωνικού δικτύου και παράλληλα η εκτίμηση των αποτελεσμάτων από τον χρήστη καθώς το νευρωνικό δίκτυο κρίνει βάσει της ιστορικότητας και δεν μπορεί να γνωρίζει εξωγενείς παράγοντες που μπορεί να επηρεάσουν τα αποτελέσματα.

5.2 Σύγκριση Μεθόδων Στελέχωσης

Όπως και με τα μοντέλα πρόβλεψης, έτσι και με τις μεθόδους για την κατανομή εργαζομένων έγινε πιλοτική χρήση του εργαλείου που δημιουργήθηκε για το ίδιο διάστημα προκειμένου να υπάρχει η δυνατότητα σύγκρισής τους. Επειδή η κατανομή των εργαζομένων και στις δύο περιπτώσεις στηρίζεται στο forecast που είναι διαφορετικό δεν μπορεί να γίνει σύγκριση μεταξύ των ατόμων που κατανεμήθηκαν και των πραγματικών αναγκών που προέκυψαν βάση των πραγματικών κλήσεων. Έτσι, οι δείκτες που χρησιμοποιήθηκαν για να συγκριθούν τα δύο μοντέλα είναι το Ratio εργαζόμενοι/κλήσεις, η μέση απόκλιση των αναγκών προς τους υπαλλήλους που χρησιμοποιήθηκαν, το παραπάνω κόστος για τις αργίες και τις βραδινές ώρες εργασίας και ο χρόνος που χρειάζεται για να γίνει η κατανομή.

Η αναλογία εργαζόμενοι προς κλήσεις υπολογίζεται σε ωριαία βάση και αναφέρεται στον αριθμο των εργαζομένων που καλούνται να απαντήσουν τον αντίστοιχο αριθμό εισερχομένων κλήσεων που έχει προβλεφθεί για την εκάστοτε ώρα. Καθώς θέλουμε ο κάθε εργαζόμενος να απαντά κατά μέσο όρο 7 κλήσεις ανά ώρα, η τιμή του αναμένεται να είναι κοντά στο 0,14. Ωστόσο, είναι προφανές πως όσο αυξάνεται η τιμή του εν λόγω δείκτη, τόσο καλύτερο γίνεται και το επίπεδο εξυπηρέτησης. Οι τιμές της κάθε μεθόδου αποτυπώνονται στον παρακάτω πίνακα (αφορούν το μέσο όρο κάθε μίας από τις οχτώ εβδομάδες).

ΠΙΝΑΚΑΣ 14 RATIO ΕΡΓΑΖΟΜΕΝΟΙ/ΚΛΗΣΕΙΣ

	Προτεινόμενη Μεθοδολογία	Υφιστάμενη Μεθοδολογία
03/10 - 09/10	0,14	0,15
10/10 - 16/10	0,14	0,15
17/10 - 23/10	0,14	0,14
24/10 - 30/10	0,17	0,13
31/10 - 06/11	0,16	0,14
07/11 - 13/11	0,15	0,14
14/11 - 20/11	0,14	0,13
21/11 - 27/11	0,14	0,13
Συνολικός ΜΟ	0,15	0,14

Όπως είναι εμφανές και στον παραπάνω πίνακα, οι αποκλίσεις είναι μικρές με εξαίρεση την εβδομάδα 31/10 – 6/11. Βέβαια, ο μέσος όρος στις οχτώ εβδομάδες είναι σχεδόν ίδιος που σημαίνει ότι και οι δύο μέθοδοι έχουν τα ίδια αποτελέσματα.

Η μέση απόκλιση των αναγκών προς τους εργαζομένους ανά ώρα μέσα στη μέρα είναι ένας εξίσου σημαντικός παράγοντας, καθώς ο στόχος είναι οι εργαζόμενοι που απασχολούνται ανά ώρα να είναι τόσοι ώστε να καλύπτουν τις κλήσεις που πρέπει να διαχειριστούν. Η ιδανική τιμή του δείκτη αυτού είναι μηδέν,

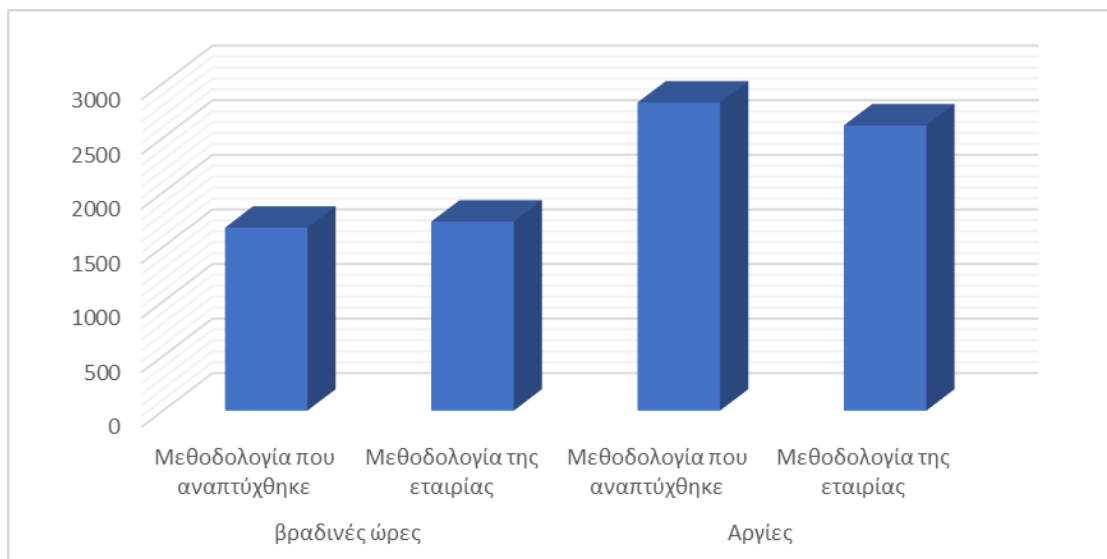
αλλά επειδή υπάρχει διακύμανση των κλήσεων μέσα στη μέρα είναι αδύνατον να επιτευχθεί. Έτσι ο στόχος είναι να βρίσκεται όσο το δυνατόν πιο κοντά στο μηδέν. Στον παρακάτω πίνακα αποτυπώνονται οι τιμές για κάθε μέθοδο σε εβδομαδιαία βάση.

ΠΙΝΑΚΑΣ 15 ΑΠΟΚΛΙΣΗ ΠΡΟΤΕΙΝΟΜΕΝΗΣ ΚΑΙ ΥΦΙΣΤΑΜΕΝΗΣ ΜΕΘΟΔΟΛΟΓΙΑΣ

	Προτεινόμενη Μεθοδολογία	Υφιστάμενη Μεθοδολογία
03/10 - 09/10	4,09	3,42
10/10 - 16/10	5,99	4,39
17/10 - 23/10	4,48	4,27
24/10 - 30/10	4,79	4,80
31/10 - 06/11	3,14	4,67
07/11 - 13/11	3,76	4,98
14/11 - 20/11	4,57	5,18
21/11 - 27/11	3,95	5,19
Συνολικός ΜΟ	4,35	4,61


Στα αποτελέσματα του παραπάνω πίνακα φαίνεται ότι ο συνολικός μέσος όρος και στις δύο μεθόδους είναι ίδιος, με την μεθοδολογία που αναπτύχθηκε να φαίνεται ελάχιστα καλύτερο αποτέλεσμα. Βέβαια, στις τρεις πρώτες εβδομάδες η μεθοδολογία της εταιρίας έχει καλύτερα αποτελέσματα, ενώ τις υπόλοιπες πέντε η μεθοδολογία που αναπτύχθηκε δείχνει καλύτερη και σε κάποιες περιπτώσεις (όπως την πέμπτη, την έκτη και την όγδοη εβδομάδα) η διαφορά είναι παραπάνω από μία μονάδα.

Όπως όλες οι εταιρίες, έτσι και τα τηλεφωνικά κέντρα επιδιώκουν να παρέχουν την καλύτερη εξυπηρέτηση με το μικρότερο κόστος. Για ένα τηλεφωνικό κέντρο που λειτουργεί όλες τις μέρες του χρόνου στο διάστημα 7:30 – 23:30 σημαίνει ότι η χρηματική δαπάνη αυξάνεται ανάλογα με το πόσα άτομα απασχολεί τις αργίες και τις βραδινές ώρες (22:00 – 23:30). Στη μεθοδολογία που αναπτύχθηκε, το σύνολο των ωρών που χαρακτηρίζονται ως βραδινές και αργίες είναι 1.676,5 και 2.823 ώρες αντίστοιχα. Στη μεθοδολογία που χρησιμοποίησε η εταιρία που έγινε η έρευνα, οι βραδινές ώρες και οι αργίες είναι 1.731,5 και 2.613 ώρες αντίστοιχα. Λαμβάνοντας υπόψιν ότι το βασικό ωρομίσθιο είναι 5,236 ευρώ, οι βραδινές ώρες και οι αργίες προσαυξάνονται κατά 0,25 και 0,75 αντίστοιχα. Η κατανομή που έγινε μέσω της μεθοδολογίας που αναπτύχθηκε δημιουργεί παραπάνω κόστος 13.280,46 ευρώ σε αντίθεση με την κατανομή που έγινε από την εταιρία που έχει παραπάνω κόστος 12.527,78. Από άποψη κόστους, η κατανομή που έγινε από την εταιρία είναι βέλτιστη κατά 752,67 ευρώ. Όλα αυτά αποτυπώνονται στο διάγραμμα παρακάτω.



ΕΙΚΟΝΑ 36 ΣΥΓΚΡΙΣΗ ΚΟΣΤΟΥΣ ΜΕΘΟΔΟΛΟΓΙΩΝ

Τέλος, σημαντικό μέτρο σύγκρισης είναι ο χρόνος που δαπανάται για την πρόβλεψη και την κατανομή των εργαζομένων. Στην εταιρία που έγινε η έρευνα, η διαδικασία διαρκεί περίπου 2 εργάσιμες μέρες (16 ώρες εργασίας) κάτι που εξαρτάται και από την εμπειρία του εργαζόμενου. Κατά την πιλοτική λειτουργία τόσο για την πρόβλεψη όσο και για την κατανομή των εργαζομένων χρειάστηκαν περίπου 8 ώρες, οι μισές δηλαδή από αυτές που χρειάζονται με τη μεθοδολογία που χρησιμοποιεί η εταιρία που έγινε η έρευνα.



ΕΙΚΟΝΑ 37 ΧΡΟΝΟΣ ΠΟΥ ΑΠΑΙΤΕΙΤΑΙ ΣΕ ΚΑΘΕ ΜΕΘΟΔΟΛΟΓΙΑ (ΩΡΕΣ)

6 Συμπεράσματα και Προοπτικές Βελτίωσης

Όπως αναφέρθηκε, σκοπός της εργασίας ήταν η έρευνα των διαθέσιμων μεθόδων πρόβλεψης εισερχομένων κλήσεων και κατανομής των διαθέσιμων εργαζομένων σε βάρδιες καθώς επίσης και η βελτιστοποίησή τους όπου ήταν δυνατή. Συγκρίνοντας τις μεθόδους που δοκιμάστηκαν τα συμπεράσματα είναι τα παρακάτω.

Σε ότι αφορά τις μεθόδους πρόβλεψης, το μοντέλο Triple Exponential Smoothing έχει τη μεγαλύτερη απόκλιση συγκριτικά με τα υπόλοιπα δύο, κάτι που το καθιστά λιγότερο αξιόπιστο. Βέβαια, για μία εταιρία που δεν θέλει να διαθέσει χρήματα για τη χρήση κάποιου προγράμματος είναι μία εύκολη και οικονομική λύση καθώς η πρόβλεψη με αυτή τη μέθοδο είναι διαθέσιμη μέσω εργαλείων του Microsoft excel. Οι διαφορές ανάμεσα στη μέθοδο Naïve και στο νευρωνικό δίκτυο που χρησιμοποιήθηκε είναι μικρές. Η πρόβλεψη της εταιρίας με τη μέθοδο Naïve όπου έγινε η έρευνα έχει μικρές αποκλίσεις από τις πραγματικές τιμές, αλλά αξίζει να σημειωθεί ότι η συγκεκριμένη μέθοδος εξαρτάται σε μεγάλο βαθμό από τον ανθρώπινο παράγοντα. Η έλλειψη εμπειρίας από τη μεριά του χρήστη μπορεί να οδηγήσει σε σημαντικά σφάλματα και σε αποτελέσματα που θα έχουν μεγάλη απόκλιση από τις πραγματικές τιμές με αποτέλεσμα να γίνει λάθος στον προγραμματισμό των εργαζομένων. Στον αντίποδα, η μέθοδος του LSTM νευρωνικού δικτύου που χρησιμοποιήθηκε έχει λίγο καλύτερα αποτελέσματα από την πρόβλεψη της εταιρίας και τα αποτελέσματά της είναι πιο αξιόπιστα καθώς δεν επηρεάζεται από τον ανθρώπινο παράγοντα. Επίσης, είναι ταχύτερη από τη μέθοδο Naïve καθώς ακόμα και στον μικρό χρόνο που χρειάζεται το πρόγραμμα να επεξεργαστεί τα δεδομένα και να προβλέψει το αποτέλεσμα, ο χρήστης μπορεί να εργάζεται σε κάτι άλλο παράλληλα. Βέβαια, αξίζει να σημειωθεί ότι το μοντέλο που χρησιμοποιήθηκε επεξεργάζεται δεδομένα μόνο βάση ιστορικότητας και δεν μπορεί να λάβει υπ' όψιν εξωγενείς παράγοντες όπως στη μέθοδο Naïve και ο χρήστης θα πρέπει να αξιολογήσει τα αποτελέσματα και να τα αναδιαμορφώσει ανάλογα με τα επιπλέον δεδομένα που έχει.

Σε ότι αφορά τη στελέχωση προσωπικού, επειδή οι μέθοδοι που χρησιμοποιούνται είναι συνήθως μέσω ολοκληρωμένων προγραμμάτων, ερευνήθηκε ο τρόπος υπολογισμού του στην εταιρία που έγινε η έρευνα και έγινε προσπάθεια αυτοματοποίησής του. Συγκρίνοντας τις δύο μεθόδους, παρατηρείται ότι τα αποτελέσματά τους δεν έχουν μεγάλες διαφορές μεταξύ τους. Στην περίπτωση του κόστους για τις αργίες και τις βραδινές ώρες, η κατανομή που έγινε από την εταιρία έχει μικρότερο κόστος. Βέβαια, αξίζει να σημειωθεί ότι εκτελώντας το εργαλείο δεν λήφθηκε υπόψιν η ελαχιστοποίηση του κόστους, αλλά δόθηκε έμφαση στη βελτιστοποίηση της κατανομής. Ένα πλεονέκτημα του εργαλείου που δημιουργήθηκε είναι η αυτοματοποίηση της διαδικασίας καθώς μειώνει την επίδραση του ανθρώπινου σφάλματος και κάνει τη διαδικασία ταχύτερη (μειώνει το χρόνο περίπου στο μισό). Τέλος, το εργαλείο που υλοποιήθηκε δίνει τη δυνατότητα

στο χρήστη να βρει τις ανάγκες που μπορεί να προκύψουν σε περιπτώσεις έλλειψης προσωπικού καθώς μπορεί να υπολογίσει τον αριθμό των υπαλλήλων που χρειάζονται χωρίς να δεσμεύεται από τον αριθμό των υπαλλήλων που απασχολούνται.

Συνοψίζοντας τα παραπάνω, αποδεικνύεται ότι ο συνδιασμός πρόβλεψης με τη μέθοδο νευρωνικού δικτύου και κατανομή των εργαζομένων με το εργαλείο που αναπτύχθηκε έχει τα βέλτιστα αποτελέσματα. Επίσης η διαδικασία είναι ταχύτερη, πιο αυτοματοποιημένη και εξαρτάται λιγότερο από τον ανθρώπινο παράγοντα σχετικά με αυτή που ακολουθείται από την εταιρία. Σε κάθε περίπτωση βέβαια, τα αποτελέσματα πρέπει να αξιολογηθούν και όπου χρειάζεται να αναδιαμορφωθούν καθώς δεν λαμβάνονται υπ' όψιν αστάθμητοι παράγοντες.

Οι μέθοδοι που υλοποιήθηκαν στην εργασία είχαν ως κύριο στόχο τη δημιουργία μιας αυτοματοποιημένης διαδικασίας. Μελλοντικά μπορούν να γίνουν αλλαγές που βελτιώνουν αυτές τις μεθόδους. Σε ότι αφορά την πρόβλεψη, η δημιουργία βαρών για κάποιες μέρες που μπορεί να χαρακτηριστούν ως special days (πχ κινητές αργίες) μπορεί να ελαχιστοποιήσει την πιθανότητα λανθασμένης πρόβλεψης από το νευρωνικό δίκτυο. Επίσης, θα βοηθούσε η παραμετροποίησή του ώστε να μην χρειάζεται να το εκτελεί ο χρήστης για κάθε μέρα ξεχωριστά (για Δευτέρες, Τρίτες κ.ο.κ.) αλλά να το εκτελεί μία φορά για όλες τις μέρες. Το εργαλείο που υλοποιήθηκε για την κατανομή των εργαζομένων σε βάρδιες, θα μπορούσε να αυτοματοποιηθεί αν υλοποιηθεί σε πρόγραμμα ώστε ο χρήστης να δίνει τις επιθυμητές τιμές και να κάνει δοκιμές μόνο του, ξεκινώντας από την επιθυμητή τιμή και αν δεν ικανοποιείται να δοκιμάζει με την αμέσως επόμενη μέχρι να πετύχει το βέλτιστο δυνατό αποτέλεσμα. Εάν συνδιαστεί με μία βάση δεδομένων όπου έχει το πρόγραμμα του κάθε εργαζομένου και προγραμματίζει τις βάρδιες για τον κάθε υπάλληλο με βάση την κατανομή που δημιουργήθηκε θα αυτοματοποιούσε ακόμα περισσότερο τη διαδικασία. Βέβαια σε αυτή την περίπτωση θα πρέπει να οριστούν παράγοντες όπως ειδικά ωράρια αν υπάρχουν για κάποιους εργαζομένους και ο προγραμματισμός να γίνεται έτσι ώστε να υπάρχει ισοκατανομή των βαρδιών. Τέλος, το ιδανικό σενάριο είναι να ομαδοποιηθούν όλα τα παραπάνω σε ένα ενιαίο πρόγραμμα που θα παρέχει ολοκληρωμένες λύσεις σε τηλεφωνικά κέντρα.

Αναφορές

- **Βασίλειος Ασημακόπουλος 2011.** Επιχειρησιακές Προβλέψεις
- **Devon Barrow, Nikolaos Kourentzes.** The impact of special days in call arrivals forecasting: A neural network approach to modelling special days. European Journal of Operational Research. 2018, σσ. 967-977
- **Mona Ebadi Jalal, Monireh Hosseini, Stefan Karlsson.** Modeling and forecasting call center arrivals: A literature survey and a case study. International Journal of Forecasting. 2016, σσ. 4811-4814
- **Ingmar Nolte, Sandra Nolte, Winfried Pohlmeier.** What determines forecasters' forecasting errors? . International Journal of Forecasting 2019, σσ. 11-24
- **Mona Ebadi Jalal, Monireh Hosseini, Stefan Karlsson.** Forecasting incoming call volumes in call centers with recurrent Neural Networks. Journal of Business Research. 2016, σσ. 4811 - 4814
- <https://www.callcentrehelper.com/the-history-of-the-call-centre-15085.htm>
- <https://www.callcentrehelper.com/workforce-forecasting-57254.htm>
- <https://www.callcentrehelper.com/the-latest-techniques-for-call-centre-forecasting-117394.htm>
- <https://machinelearningmastery.com/multi-step-time-series-forecasting-long-short-term-memory-networks-python/>
- <https://skymind.ai/wiki/lstm>
- https://en.wikipedia.org/wiki/Long_short-term_memory
- <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- <https://www.colourbox.com/vector/support-call-center-infographics-vector-12831077>
- <https://www.digitaltrends.com/cool-tech/what-is-an-artificial-neural-network/>
- <https://medium.com/@jamesdacombe/an-introduction-to-artificial-neural-networks-with-example-ad459bb6941b>
- <https://towardsdatascience.com/introduction-to-neural-networks-advantages-and-applications-96851bd1a207>
- https://en.wikipedia.org/wiki/Machine_learning
- <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>