



ΧΑΡΟΚΟΠΕΙΟ ΠΑΝΕΠΙΣΤΗΜΙΟ
HAROKOPIO UNIVERSITY

Π.Μ.Σ. ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΜΑΤΙΚΗΣ
ΠΛΗΡΟΦΟΡΙΑΚΑ ΣΥΣΤΗΜΑΤΑ ΣΤΗ ΔΙΟΙΚΗΣΗ
ΕΠΙΧΕΙΡΗΣΕΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Σοφιανόπουλος Κωνσταντίνος | ΑΜ: 14317

ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΑΥΞΗΣΗΣ ΑΠΟΚΡΙΣΗΣ ΣΤΗΝ
ΠΡΩΘΗΣΗ ΠΡΟΪΟΝΤΩΝ

-

UPLIFT MODELING IN DIRECT MARKETING

Αθήνα, Σεπτέμβριος 2016

Επιβλέπων:

Ηρακλής Βαρλάμης

Μέλη Τριμελούς:

Επικ. Καθηγητής Κων/νος Τσερπές

Επικ. Καθηγητής Χρήστος Μιχαλακέλης

ΠΕΡΙΕΧΟΜΕΝΑ

Εισαγωγή

- 1.1 Ορισμός
- 1.2 Προϊστορία
- 1.3 Παράδειγμα
- 1.4 Διαφορές Uplift με τα παραδοσιακά μοντέλα απόκρισης
- 1.5 ROI - Return on Investment
- 1.6 Σκοπός της εργασίας

Υπόβαθρο

- 2.1. Εφαρμογές των Uplift μοντέλων
- 2.2 Ιατρική - Uplift μοντέλα σε κλινικές δοκιμές
- 2.3 Τηλεπικοινωνίες - Το παράδειγμα της Telenor
- 2.4 Πολιτική - Αμερικάνικες Προεδρικές Εκλογές

Μεθοδολογία & Προσεγγίσεις του Uplift Modeling

- 3.1 Μεθοδολογία
- 3.2 Πως αξιολογούμε την απόδοση ενός μοντέλου;
- 3.3 Προκλήσεις στην εφαρμογή του Uplift Modeling
- 3.4 Εργαλεία
- 3.5 Πλεονεκτήματα
- 3.6 Αρνητικές επιπτώσεις

Εκτίμηση κόστους / όφελους

- 4.1 Project
- 4.2 Αποτελέσματα

Συμπεράσματα - Μελλοντικά βήματα

- 5.1 Τα Uplift μοντέλα λειτουργούν πραγματικά;
- 5.2 Η κατάσταση σήμερα
- 5.3 Το μέλλον

Βιβλιογραφία

Παράρτημα

Εισαγωγή

Αρκετές marketing καμπάνιες απευθύνονται σε τυχαία επιλεγμένους πελάτες, συχνά δημιουργώντας τεράστιο κόστος και μη αναμενόμενη απόκριση. Επιπλέον, τέτοιου είδους καμπάνιες έχουν την τάση να ενοχλούν αδικαιολόγητα τους πελάτες και να κάνουν λιγότερο πιθανή τη θετική ανταπόκριση σε μελλοντικές ενέργειες.

Οι επαγγελματίες του marketing προσπαθούν να διαχειριστούν τη μετακίνηση των πελατών σε ανταγωνιστές. Η μεγάλη πλειονότητα επικεντρώνεται στην προσθήκη νέων πελατών και όχι τη διατήρηση των υφιστάμενων. Αλλά σε ένα οικονομικό περιβάλλον όπου η ανάπτυξη είναι αργή, τα προγράμματα διατήρησης πελατών αποκτούν μεγαλύτερη σημασία. Παρόλα αυτά, οι επιχειρήσεις αγωνίζονται για να διαχειριστούν τα προγράμματα διατήρησης των πελατών επειδή:

· **Αποτυγχάνουν να συμφωνήσουν σε έναν κοινό όρο για τις απώλειες των πελατών.**

Η απώλεια των πελατών είναι ένα δύσκολο θέμα για επαγγελματίες του marketing. Πολύ συχνά δε φαίνεται να συμφωνούν για το πότε και με ποιο ρυθμό γίνεται αυτή η απώλεια και ποια είναι η διαδικασία προσδιορισμού των πελατών που μπορεί να χαθούν(churners). Για παράδειγμα, οι χρηματοπιστωτικές εταιρείες χαρακτηρίζουν ως φθορά τα εξής:

- μείωση της δραστηριότητας
- μείωση του μέσου όρου υπολοίπων
- μείωση του αριθμού των λογαριασμών.

Η διαφωνία σχετικά με τον πραγματικό ορισμό καθιστά δύσκολο για τους επαγγελματίες να δημιουργήσουν διαδικασίες που θα μετρήσουν και θα αντιμετωπίσουν το πρόβλημα.

· **Δεν έχουν την ικανότητα να στοχεύουν με κατάλληλες προσφορές.**

Ο εντοπισμός των πελατών που είναι πιθανό να χαθούν είναι μόνο το πρώτο βήμα. Μετά από αυτό, είναι απαραίτητο να αξιοποιηθεί κατάλληλο προσωπικό και κανάλια για να φτάσουν σε αυτούς τους πελάτες οι σχετικές προσφορές. Αυτή η διαδικασία είναι ιδιαίτερα κρίσιμη, διότι οι λάθος προσφορές μπορεί να προκαλέσουν απώλειες, το ακριβώς αντίθετο αποτέλεσμα από αυτό που πρέπει να επιτευχθεί.

- Προσπαθούν να διατηρήσουν όλους τους πελάτες, όχι μόνο τους κερδοφόρους.

Όταν πρόκειται για τη διατήρηση πελατών, οι επαγγελματίες του marketing αντιμετωπίζουν όλους τους πελάτες ισάξια. Λίγοι οργανισμοί έχουν μεθοδολογίες αποτίμησης - όπως κερδοφορία των πελατών, το προφίλ κινδύνου του πελάτη ή την αξία τους στο χρόνο - ώστε να κατηγοριοποιούν τους πελάτες με βάση την αξία τους. Αυτό σημαίνει ότι τα προγράμματα διατήρησης προσεγγίζονται τυχαία, με αποτέλεσμα να δαπανώνται πολύτιμοι πόροι για τη διατήρηση ασύμφορων πελατών. Όταν ένας πελάτης δεν είναι εντελώς ανώνυμος, μια εταιρεία μπορεί να στείλει άμεσα προσφορές σε αυτόν. Για παράδειγμα, οι προσφορές των προϊόντων ή υπηρεσιών μια εταιρείας μπορεί να αποσταλούν μέσω email ή με το παραδοσιακό ταχυδρομείο. Συχνά, οι εταιρείες τηλεπικοινωνιών διαφημίζουν τις υπηρεσίες τους μέσω SMS, φωνητικών κλήσεων ή και άλλων διαύλων επικοινωνίας. Για να είναι αυτές οι εκστρατείες αποτελεσματικές θα πρέπει να απευθύνονται σε εκείνους που έχουν τη μεγαλύτερη πιθανότητα να ανταποκριθούν θετικά π.χ. να αγοράσουν ένα προϊόν ή να επισκεφθούν μια ιστοσελίδα. Μια σωστά στοχευμένη εκστρατεία θα αποφέρει μεγαλύτερη απόδοση της επένδυσης (ROI) από μια με ελλιπή στόχευση. Το ακόμη σημαντικότερο είναι πως δε θα ενοχλήσει όσους δεν ενδιαφέρονται πραγματικά για την προσφορά.

Η ακριβής στόχευση των ενεργειών marketing μπορεί να οδηγήσει δυνητικά σε μεγαλύτερη απόδοση της επένδυσης (ROI). Τα συνήθη μοντέλα απόκρισης που χρησιμοποιούνται, στοχεύουν στην επίτευξη υψηλής ακρίβειας πρόβλεψης για την πιθανότητα να πραγματοποιηθούν αγορές με βάση ένα δείγμα πελατών, στο οποίο πιλοτικά έχει σταλεί μια ενέργεια. Για να διαχωριστεί η επίπτωση της ενέργειας αυτής από άλλα ερεθίσματα και αυθόρμητες αγορές που προκύπτουν, θα πρέπει να υπολογιστεί η αλλαγή σε αυτές τις πιθανότητες, μετά και την επίδραση της ενέργειας.

Ο υπολογισμός αυτής της πρόβλεψης είναι γνωστός ως Uplift Modeling.

1.1 Ορισμός

Uplift modelling ή αλλιώς incremental modelling, true lift modelling ή net modelling είναι ένα μοντέλο που προβλέπει άμεσα την επίδραση μιας ενέργειας, π.χ marketing ενέργειας στην επίδραση μιας ομάδας ατόμων. Πρόκειται για μια τεχνική εξόρυξης δεδομένων που εφαρμόζεται με επιτυχία στον οικονομικό τομέα, στις τηλεπικοινωνίες και στο άμεσο marketing για αύξηση των πωλήσεων (up-sell), cross-sell τεχνικές, καθώς και την απόκτηση και διατήρηση πελατών.

Ο όρος Uplift επινοήθηκε στο πλαίσιο των άμεσων εφαρμογών marketing, όπου τα προβλήματα που αντιμετωπίζονται είναι αρκετά παρόμοια με τις κλινικές δοκιμές: μια

εκστρατεία παίζει το ρόλο της θεραπείας. Μια εκστρατεία μπορεί να έχει αρνητική επίδραση στους πελάτες, ακόμα περισσότερο μπορεί να τους ωθήσει στο να εγκαταλείψουν την εταιρεία και μπορεί να θεωρηθεί ανάλογη των παρενεργειών μια ιατρικής θεραπείας. [Radcliffe & Surry, 1999]. Όπως το περιγράφει και ένας από τους εμπνευστές της θεωρίας του Uplift Modelling:

“ Uplift is the Difference Between Purchase Probability With and Without Treatment. ” - [Radcliffe, 2007]

1.2 Προϊστορία

Η πρώτη εμφάνιση της Uplift μοντελοποίησης είναι στις εργασίες του Radcliffe και Surry [Radcliffe & Surry, 1999]. Ο Victor Lo δημοσίευσε επίσης για το θέμα αυτό στο άρθρο του “The True Lift Model” [Lo, 2002]. Ο Radcliffe χρησιμοποίησε ομάδες ελέγχου (control groups) στις οποίες δεν εφαρμόζεται καμία παρέμβαση και ομάδες στόχου (target groups) στις οποίες εφάρμοσε τη διαφημιστική παρέμβαση, με στόχο την πρόβλεψη του Uplift [Radcliffe, 2007b]. Ο ίδιος παρέχει επίσης μια πολύ χρήσιμη ενότητα συχνών ερωτήσεων (FAQ) στην ιστοσελίδα του¹. Παρόμοιες προσεγγίσεις έχουν πραγματοποιηθεί και στην εξατομικευμένη ιατρική [Cai et al, 2009].

Τα Uplift μοντέλα είναι μια ειδική περίπτωση της παλαιότερης διαφορικής πρόβλεψης. Σε αντίθεση με τη διαφορική πρόβλεψη, η Uplift μοντελοποίηση αναλαμβάνει έναν ενεργό παράγοντα και χρησιμοποιεί το **uplift** ως μετρική βελτιστοποίησης.

1.3 Παράδειγμα

Η Uplift μοντελοποίηση δεν μπορεί να γνωρίζει την αλλαγή της συμπεριφοράς για κάθε άτομο, όχι περισσότερο από ότι ένα κανονικό μοντέλο μπορεί να το επιτύχει. Αλλά μπορεί να την προβλέψει. Αυτό επιτυγχάνεται με την εξέταση δύο ομάδων ανθρώπων, ένας εκ των οποίων ήταν αντικείμενο της δράσης εμπορίας και η άλλη των οποίων δεν ήταν (ομάδα ελέγχου). Ακριβώς όπως είναι πρότυπο για τη μέτρηση της τάσης αύξησης μιας εκστρατείας κοιτάζοντας τη συνολική διαφορά στην τιμή αγοράς μεταξύ της ομάδας αντιμετωπίζονται και μια κατά τα άλλα ισοδύναμη ομάδα ελέγχου , ανάταξη μοντέλα προσομοίωσης τη διαφορά στη συμπεριφορά μεταξύ των δύο αυτών ομάδων , βρίσκοντας μοτίβα στην παραλλαγή.

Ο παρακάτω πίνακας απεικονίζει τις λεπτομέρειες μια καμπάνιας απεικονίζοντας τον αριθμό απαντήσεων και το τελικό ποσοστό απαντήσεων της καμπάνιας.

¹ <http://scientificmarketer.com/2007/09/uplift-modelling-faq.html>

Group	Αριθμός πελατών	Απαντήσεις	Ποσοστό απαντήσεων
Treated (έχει δεχτεί την ενέργεια)	1.000.000	100.000	10%
Control (δεν έχει δεχτεί την ενέργεια)	1.000.000	80.000	8%

Συμπερασματικά από τα αποτελέσματα του πίνακα προκύπτει ότι η Marketing ενέργεια απέδωσε:

- Uplift του ποσοστού απαντήσεων κατά 2%
- Σε αριθμό: 20.000 incremental απαντήσεις

1.4 Διαφορές Uplift με τα παραδοσιακά μοντέλα απόκρισης

Η Uplift μοντελοποίηση δεν μπορεί να γνωρίζει την αλλαγή της συμπεριφοράς για κάθε άτομο, περισσότερο από ότι ένα οποιοδήποτε κανονικό μοντέλο πρόβλεψης (π.χ. Μοντέλα παλινδρόμησης). Μπορεί όμως να μοντελοποιήσει καλύτερα την αυξητική συμπεριφορά σε μια ομάδα ατόμων που θα δεχτεί μια παρέμβαση (π.χ. Μια προωθητική ενέργεια) σε σχέση με μια ομάδα που δεν θα τη δεχθεί. Αυτό επιτυγχάνεται με την εξέταση δύο ομάδων ανθρώπων, μία εκ των οποίων λαμβάνει την όποια ενέργεια (target) και η άλλη όχι (control). Τα παραδοσιακά μοντέλα απόκρισης έχουν βελτιστοποιηθεί ώστε να αναζητούν άτομα που θα ανταποκριθούν, άσχετα από την ίδια την προωθητική ενέργεια (natural responders) και ως εκ τούτου δεν είναι ιδιαίτερα αποδοτικά. Από την άλλη, τα Uplift μοντέλα έχουν βελτιστοποιηθεί για να βρίσκουν τα άτομα που θα ανταποκριθούν εξαιτίας της ενέργειας, με αποτέλεσμα τα χρήματα που ξοδεύονται για αυτή να αφορούν αυτούς και μόνο. Βελτιώνουν την αποτελεσματικότητα των ενεργειών που στοχεύουν άμεσα τον πελάτη ενώ μειώνουν τη δυσαρέσκεια των πελατών που δεν σκοπεύουν να ανταποκριθούν ή που ενοχλούνται από τις συνεχείς παρεμβάσεις, όπως μπορεί συχνά να συμβεί σε μεγάλες καμπάνιες χρηματοπιστωτικών ιδρυμάτων και εταιρειών τηλεπικοινωνίας.

Τα παραδοσιακά μοντέλα απόκρισης δεν μοντελοποιούν την αλλαγή στη συμπεριφορά, αλλά τη συμπεριφορά κάποιου που έχει δεχτεί μια εκστρατεία. Από την άλλη, με τα Uplift μοντέλα είναι δυνατό να μοντελοποιηθεί η αλλαγή στη συμπεριφορά των ατόμων: πόσα θα ξοδέψει ένα άτομο, πόσο πιθανό είναι να φύγει κλπ.

Το Uplift μιας Marketing ενέργειας συνήθως ορίζεται ως η διαφορά που προκύπτει από την ανταπόκριση μεταξύ του treated group και ενός τυχαίου control group.

- Το treated group περιλαμβάνει όλα εκείνα τα άτομα που δέχτηκαν μια συγκεκριμένη Marketing ενέργεια.
- Το τυχαίο control group περιλαμβάνει όλους εκείνους που εξαιρέθηκαν από την παραπάνω Marketing ενέργεια.

Παραδείγματα τέτοια είναι:

- Προ-εγκριμένες πιστωτικές κάρτες
- 50% έκπτωση σε κατάσταση λιανικής μια συγκεκριμένη μέρα

Τυχαίο γκρουπ σημαίνει πως τα άτομα που ανήκουν σε αυτό έχουν αντίστοιχα χαρακτηριστικά με εκείνα που ανήκουν στο treated group. Η μόνη διαφορά είναι πως το treated group έλαβε την ενέργεια ενώ το control group όχι.

Είναι πολύ σημαντικό για μία εταιρεία να ορίσει τα Test και Control γκρουπ σωστά, ώστε να μπορεί να απομονώσει την επίδραση της Marketing ενέργειας και να αξιολογήσει την αποτελεσματικότητά της.

Μαθηματικά, ένα μοντέλο απόκρισης προβλέπει ως εξής την πιθανότητα αγοράς μετά από μία ενέργεια.

$$P \text{ (purchase | treatment)}$$

Τα Uplift μοντέλα από την άλλη προβλέπουν ως εξής:

$$P \text{ (purchase | treatment)} - P \text{ (purchase | no treatment)}$$

δηλαδή τη διαφορά μεταξύ της πιθανότητας αγοράς μετά από μια συγκεκριμένη ενέργεια και εκείνης χωρίς να έχει προηγηθεί κάποια. [Radcliffe, 2007]

Τα παραδοσιακά μοντέλα απόκρισης συνήθως βασίζονται σε μία ομάδα πελατών που έχουν ήδη υποβληθεί σε μία ενέργεια και προσπαθούν να χτίσουν ένα προγνωστικό μοντέλο που θα διαχωρίσει αυτούς που θα ανταποκριθούν με εκείνους που δε θα το κάνουν, μέσω της χρήσης τεχνικών μοντελοποίησης πρόβλεψης. Συνήθως αυτές είναι τα δέντρα απόφασης ή η ανάλυση παλινδρόμησης.

Αντίθετα, τα Uplift μοντέλα χρησιμοποιούν τόσο το control όσο και το treated group για να δημιουργήσουν ένα προγνωστικό μοντέλο που εστιάζει στην αυξανόμενη ανταπόκριση. Για να κατανοήσουμε αυτό το είδος μοντέλου προτείνεται μια θεμελιώδη κατάτμηση των πελατών σε ακόλουθες ομάδες, όπως θα δούμε παρακάτω.

Συνολικά, πρόκειται για μια υψηλού επιπέδου τεχνική μοντελοποίησης για την ταυτοποίηση πιθανών πελατών μέσω marketing και ενεργειών διατηρησιμότητας. Χρησιμοποιείται από μεγάλες εταιρείες για τη λήψη καλύτερων και αποδοτικότερων αποφάσεων.

1.5 ROI - Return on Investment

Ένα μέτρο απόδοσης που χρησιμοποιείται για την αξιολόγηση της αποτελεσματικότητας μιας επένδυσης ή να συγκρίνει την αποτελεσματικότητα ενός αριθμού διαφορετικών επενδύσεων. Με το ROI μετράται η ποσότητα της απόδοσης της επένδυσης σε σχέση με το κόστος της. Για τον υπολογισμό του, το όφελος (ή επιστροφή) της επένδυσης χωρίζεται από το κόστος της επένδυσης και το αποτέλεσμα εκφράζεται ως ποσοστό ή αναλογία.

Ο τύπος υπολογισμού του ROI:

$$ROI = \frac{(\text{Gain from Investment} - \text{Cost of Investment})}{\text{Cost of Investment}}$$

Στον παραπάνω τύπο, το **κέρδος από επενδύσεις** αναφέρεται στα έσοδα που προέρχονται από την πώληση που αφορά την επένδυση. Επειδή η απόδοση της επένδυσης υπολογίζεται ως ποσοστό, μπορεί εύκολα να συγκριθεί με αποδόσεις άλλων επενδύσεων, επιτρέποντας στον ερευνητή τις απαραίτητες συγκρίσεις.

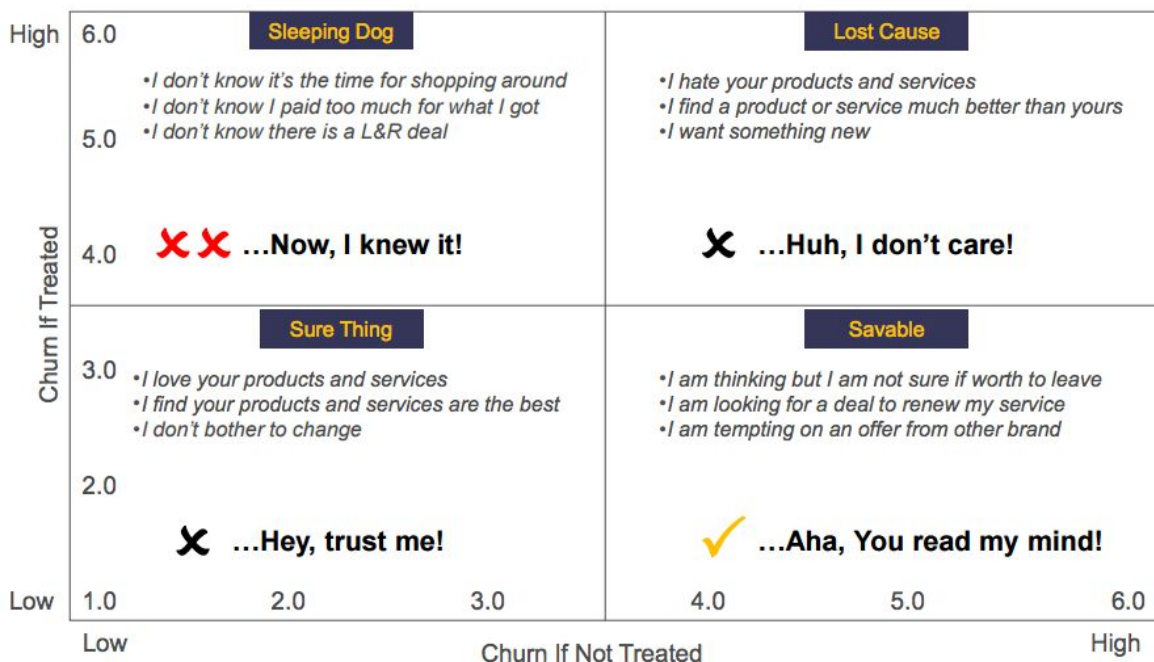
Για άμεσες ενέργειες προώθησης, η επαφή πραγματοποιείται μέσω ενός άμεσου καναλιού. Οι πελάτες που είναι πιθανότερο να ανταποκριθούν ή να χαθούν βρίσκονται στη στόχευση και οι δημοφιλέστερες λύσεις μοντελοποίησης είναι :

- **Το λογιστικό μοντέλο:** Δημιουργήθηκε για να εντοπίζει τις τάσεις των πελατών σχετικά με την απόκτηση ενός προϊόντος ή την ενεργοποίηση μιας υπηρεσίας.

- **Το μοντέλο επιβίωσης:** Δημιουργήθηκε για να εντοπίζει το πόσο πιθανό είναι να χαθεί ένας πελάτης.

Τις περισσότερες φορές, αυτά χαρακτηρίζονται ως Response Models (μοντέλα απόκρισης). Ωστόσο, τα μοντέλα αυτά κάνουν μια μεγάλη υπόθεση: μια εκστρατεία άμεσου marketing θα επιτύχει το μέγιστο ποσοστό απόκρισης όταν στοχευθεί ένα γκρουπ από τους καλύτερους πελάτες. Ένα μοντέλο απόκρισης (Response Model) από μόνο του δεν πρόκειται να πει στον ερευνητή ποιοι πελάτες είναι πιθανότερο να συμβάλουν στη σταδιακή ανταπόκριση της εκστρατείας. Απαιτείται ένα εναλλακτικό στατιστικό μοντέλο, με στόχο τους πελάτες των οποίων οι τάσεις της απόκρισης να επηρεάζονται δραματικά από την ίδια την ενέργεια.

Όπως φαίνεται στο παρακάτω γράφημα,



Σχήμα 1, Πηγή: Ryan Zhao, Improve Marketing Campaign ROI using Uplift, 2012

Θέλουμε να δώσουμε προσοχή στους **Savables**, εκείνους τους καταναλωτές που θα αγοράσουν μόνο εάν λάβουν μια προσφορά. Γιατί να επενδύσουμε χρήματα στο marketing για εκείνους που πρόκειται να αγοράσουν έτσι κι αλλιώς, σε όσους δε θέλουν να λάβουν την προσφορά μας ή σε εκείνους που δε θα την εξετάσουν;

Η μόνη ομάδα που μπορεί να επιτύχει αυξητική απόκριση είναι οι Savables.

Τα Uplift μοντέλα παρέχουν μια τεχνική βαθμολόγησης που μπορεί να διαχωρίσει τους πελάτες στις ομάδες που περιγράφονται παραπάνω. Τα παραδοσιακά μοντέλα συχνά στοχεύουν τους **Sure Things** καθώς δεν είναι σε θέση να τους διακρίνουν από τους **Savables**.

1.6 Σκοπός της εργασίας

Η παρούσα διπλωματική εργασία έρχεται να μελετήσει και να αναδείξει ένα από τα πλέον σύγχρονα μοντέλα προβλέψεων. Σε μια στιγμή που ο κόσμος των επιχειρήσεων αντιμετωπίζει καθημερινά την πρόκληση για τη μεγαλύτερη δυνατή ελαχιστοποίηση του προϋπολογισμού marketing ενεργειών, τα Uplift μοντέλα αποτελούν ένα πολύ ισχυρό εργαλείο. Παρά την απόδοσή τους, δεν έχουν υιοθετηθεί ακόμα στο επίπεδο που τους αναλογεί.

Σκοπός της εργασίας είναι πρωτίστως να αναδείξει την ιστορία και την πετυχημένη εφαρμογή τους και το πως μπορούν να έχουν αξία από επιχειρηματική σκοπιά. Αποτελεί συνολικά το εφελκυστικό για περαιτέρω ενασχόληση με τα μοντέλα προβλέψεων και τη δύναμη που προσφέρουν σε ερευνητές και επαγγελματίες τους marketing.

Υπόβαθρο

2.1. Εφαρμογές των Uplift μοντέλων

Η προσέγγιση του Uplift Modeling αποσκοπεί στη διατήρηση των πελατών, προβλέποντας ποιοι πελάτες παρουσιάζουν τη μεγαλύτερη πιθανότητα απώλειας και στη συνέχεια στοχεύουν εκείνους που διατρέχουν υψηλό κίνδυνο ο οποίος είναι επίσης υψηλής αξίας με κάποια δραστηριότητα διατήρησης. Δυστυχώς, αυτές οι προσπάθειες διατήρησης αρκετά συχνά αποτυγχάνουν, προκαλώντας μάλιστα μεγαλύτερη φθορά από εκείνη που ήθελαν να διασώσουν. Τα Uplift μοντέλα μπορούν να χρησιμοποιηθούν για τον εντοπισμό των ατόμων που μπορούν να σωθούν από μια καμπάνια διατήρησης πελατών. Εδώ μάλιστα παρατηρείται μια τριπλή νίκη, γιατί μειώνεται το ποσοστό τριβής (αυξάνοντας έτσι το ποσοστό διατήρησης), μειώνεται ο όγκος στόχευσης (επομένως εξοικονομούνται χρήματα) και ταυτόχρονα μειώνεται η δυσαρέσκεια από τους πελάτες.

Οι άλλες μεγάλες επιτυχίες σημειώνονται στον τομέα του cross-sell και up-sell, ιδιαίτερα των χρηματοοικονομικών προϊόντων υψηλής αξίας. Σε αυτόν τον τομέα, οι τιμές αγοράς είναι συχνά χαμηλές και η συνολική αυξητική επίδραση των εκστρατειών επίσης μικρή. Η χρήση ενός uplift μοντέλου επιτρέπει τη δραματική μείωση του όγκου στόχευσης, διατηρώντας τον αριθμό πωλήσεων. Σε ορισμένες περιπτώσεις, ο αριθμός των πωλήσεων αυξάνεται στην πραγματικότητα, παρά τη μικρότερη στόχευση.

Για να εκτελεστεί μια πραγματικά επιτυχημένη εκστρατεία πρέπει να είμαστε σε θέση να επιλέξουμε τους πελάτες που θα αγοράσουν λόγω της επίδρασης της εκστρατείας, δηλαδή εκείνους που είναι πιθανό να αγοράσουν αν στοχευθούν και είναι απίθανο να αγοράσουν διαφορετικά. Παρόμοια προβλήματα προκύπτουν στην ιατρική, όπου ορισμένοι ασθενείς μπορεί να ανακάμψουν χωρίς στην πραγματικότητα να ακολουθούν θεραπεία και ορισμένοι μπορεί να αντιμετωπίσουν αρνητικές παρενέργειες λόγω της θεραπείας, περισσότερες και από την ίδια την ασθένεια. Τα Uplift μοντέλα παρέχουν τη λύση και σε αυτό το πρόβλημα.

Η προσέγγιση χρησιμοποιεί δύο ξεχωριστά σετ εκπαίδευσης: το target (ή treatment) group και το control. Τα αντικείμενα στο σύνολο δεδομένων που θα υποβληθούν σε κάποια δράση, όπως μια ιατρική θεραπεία ή μια εκστρατεία marketing. Το Control Group περιέχει αντικείμενα που δεν έχουν υπαχθεί στη δράση και χρησιμεύει ως

πλαίσιο εντός του οποίου μπορεί να αξιολογηθεί η επίδρασή της ενέργειας. Αντί της μοντελοποίησης βάσει πιθανοτήτων, τα Uplift μοντέλα επιχειρούν να διαμορφώσουν τη διαφορά μεταξύ της τάξης πιθανοτήτων των 2 γκρουπ. Με αυτό τον τρόπο, η επιρροή της δράσης μπορεί να μοντελοποιηθεί και η μέθοδος είναι σε θέση να προβλέψει την πραγματική απολαβή από τη στόχευση συγκεκριμένων ατόμων. Μέχρι σήμερα, τα Uplift μοντέλα έχουν εφαρμοστεί με επιτυχία σε καμπάνιες επιχειρήσεων.


2.2 Ιατρική - Uplift μοντέλα σε κλινικές δοκιμές

Με τη χρήση ενός Uplift μοντέλου αποδείχθηκε πως είναι δυνατό να επιλεγούν ασθενείς που θα ωφεληθούν από μία θεραπεία. Ακόμη και αν η συνολική θεραπεία δεν είναι επωφελής, ή έχει υψηλότερη πιθανότητα για εμφάνιση παρενεργειών, η χρήση ενός Uplift μοντέλου μπορεί να επιλέξει μια ομάδα ασθενών για τους οποίους η θεραπεία θα είναι επιτυχής, ή θα έχει αντίστοιχα χαμηλή συχνότητα παρενεργειών. Η χρήση Uplift μοντέλων εφαρμόστηκε για τη μοντελοποίηση δεδομένων σχετικά με τη μεταμόσχευση Μυελού των Οστών [Pintilie, 2006]. Η αρχική μελέτη περιγράφηκε από τον Couban [2002] με τα δεδομένα να καλύπτουν τους ασθενείς που έλαβαν δύο τύπους μυελού των οστών:

- Η μία περίπτωση είναι από τον πνευλικό οστό.
- Και η άλλη από το περιφερικό αίμα, μια νέα προσέγγιση.

Η πρώτη ομάδα αποτέλεσε το Test Group ενώ η δεύτερη το Control Group.

Υπάρχουν μόνο τρεις μεταβλητές τυχαιοποίησης. Η τιμή στόχου επιλέχθηκε να είναι η εμφάνιση της χρόνιας νόσου μοσχεύματος έναντι του ξενιστή (GVHD). Η μη εμφάνιση είναι η επιτυχής έκβαση. Όπως σημειώνεται από τον Couban, η μεταμόσχευση του περιφερικού αίματος είναι γενικά η προτιμώμενη θεραπεία, με την ελαχιστοποίηση των παρενεργειών να είναι ιδιαίτερα επιθυμητή. Το Uplift φαίνεται στο Σχήμα 2. Σε γενικές γραμμές, η θεραπεία με βάση κύτταρα του περιφερικού αίματος έχει πολύ υψηλότερη συχνότητα εμφάνισης της χρόνιας GVHD ενώ το ποσοστό επιτυχίας είναι περίπου 10% χαμηλότερο. Ωστόσο, αξιοποιώντας τα Uplift μοντέλα για την επιλογή των ασθενών για τη θεραπεία που βασίζεται στο περιφερικό αίμα, αυτή μπορεί να εφαρμοστεί σε σχεδόν το 70% του πληθυσμού επιτυγχάνοντας 2% χαμηλότερη εμφάνιση GVHD σε σχέση με την ομάδα ελέγχου.



Σχήμα 2, Πηγή: Maciej Jaskowski & Szymon Jaroszewicz, *Uplift Modeling for Clinical Trial Data*

2.3 Τηλεπικοινωνίες - Το παράδειγμα της Telenor


Μια μελέτη περίπτωσης για να κατανοήσουν καλύτερα πώς οι οργανισμοί μπορούν να χρησιμοποιούν τα Uplift μοντέλα για να βελτιώσουν τις επιδόσεις τους είναι τα προγράμματα διατήρησης πελατών των εταιριών τηλεπικοινωνιών. Η Telenor αποτελεί την έβδομη μεγαλύτερη εταιρεία κινητής τηλεφωνίας στον κόσμο και διαθέτει κινητές και σταθερές γραμμές, ευρυζωνικές υπηρεσίες υπηρεσίες τηλεόρασης.

Σε μια αγορά γεμάτη από ανταγωνιστές με υπηρεσίες χαμηλού κόστους, η Telenor είναι κυρίαρχος παίκτης της Νορβηγίας στις τηλεπικοινωνίες με μερίδιο αγοράς άνω του 50% και ευρεία κάλυψη δικτύου. Για την καταπολέμηση στρατηγικών απόκτησης πελατών με βάση τις χαμηλές τιμές, η Telenor διεύρυνε τα προγράμματά των πελατειακών σχέσεων, δίνοντας μεγαλύτερη έμφαση στην εξυπηρέτηση πελατών και τις υπηρεσίες προστιθέμενης αξίας. Παράλληλα, επικεντρώθηκε στη διατήρηση των πελατών.

Οι επιχειρήσεις στις ώριμες αγορές με πτωτικές πιέσεις στις τιμές ρίχνουν το βάρος στην απώλεια και σχεδιάζουν προγράμματα για να διατηρήσουν και να εμβαθύνουν τις υπάρχουσες σχέσεις. Η Telenor δε διαφέρει.

Ωστόσο, για να καταφέρει πραγματικά να επικεντρωθεί στις δραστηριότητες διατήρησης πελατών, προσαρμοσε όλα τα σχετικά προγράμματα στους πολυτιμότερους εξ'αυτών. Μια ευρεία ποικιλία μετρήσεων - όπως το πακέτο, ο όγκος κλήσεων και ο επιπλέον αριθμός προϊόντων - βοηθούν την εταιρεία να εκχωρήσει αξία για τον πελάτη. Η χρήση Uplift μοντέλων μείωσε τη δυσαρέσκεια κατά 1,8%. Η ομάδα Analytics αξιοποιεί ευρεία ποικιλία χαρακτηριστικών πελατών από τα συστήματα χρέωσης, τις βάσεις δεδομένων εξυπηρέτησης και τα συστήματα CRM. Η ομάδα χρησιμοποιεί αυτά τα δεδομένα για την κατασκευή πολλών μοντέλων απώλειας και τάσης αγοράς για να εκτιμήσει τη συμπεριφορά των πελατών. Επιπλέον, η ομάδα βελτιώνει τις ενέργειες διατήρησης, χρησιμοποιώντας μια προσέγγιση που διαιρεί τους πελάτες με βάση την τάση τους και την αξία τους για τον οργανισμό.

Αυτή η προσέγγιση τμηματοποίησης βοηθά την Telenor στον εντοπισμό των Savables και δίνει προτεραιότητα στις επενδύσεις στα προγράμματα διατήρησης με βάση την αξία. Ενώ τα προγράμματα διατήρησης απέδωσαν καλά, ήταν σε θέση να μειώσει την ετήσια απώλεια κατά 5% μεταξύ των πιο πολύτιμων πελατών της, ταυτόχρονα αποκαλύφθηκαν επίσης κάποιες εντυπωσιακές πληροφορίες. Τα προγράμματα διατήρησης προκάλεσαν υψηλά επίπεδα διακοπής συμβολαίων - λίγο περισσότερο από το 50% των πελατών που απέρριψε την προσφορά στη συνέχεια αποχώρησε (Σχήμα 3). Για την αντιμετώπιση αυτού του προβλήματος, η Telenor αξιοποίησε τα Uplift μοντέλα. Τα αποτελέσματα ήταν αποκαλυπτικά:



Σχήμα 3, Πηγή: *Optimizing Customer Retention Programs*

Πτώση στα ποσοστά τριβής. Η Telenor διαπίστωσε ότι στοχεύοντας μόνο τους Persuadables, ήταν σε θέση να μειώσει το συνολικό ποσοστό αποσυνδέσεων κατά 1,8%. Οι βελτιώσεις μάλιστα οδηγήθηκαν από τη στόχευση του 60% των πιθανότερων πελατών για απώλεια. Τα οφέλη της στόχευσης σε μικρότερες ομάδες είναι σαφή - εξοικονόμηση κόστους που επιτυγχάνεται από λιγότερες επαφές και μείωση της τριβής των πελατών μέσω επιλεκτικών επαφών. Βελτιωμένη απόδοση της επένδυσης (ROI) κατά το πρώτο έτος. Ο συνδυασμός της αύξησης των ποσοστών διατήρησης και το χαμηλότερο κόστος σημαίνει ότι η Telenor θα πραγματοποιήσει αύξηση του Uplift κατά 11 μονάδες σε σχέση με τα υφιστάμενα προγράμματα.

2.4 Πολιτική - Αμερικάνικες Προεδρικές Εκλογές

Πίσω στο 2010, με τους Ρεπουμπλικανούς να κερδίζουν τον έλεγχο της Βουλής των Αντιπροσώπων, πολλές από τις αυθεντίες έστρεψαν το βλέμμα τους στις προεδρικές εκλογές του 2012 προβλέποντας ήττα για τον Πρόεδρο Ομπάμα. Οι διαχειριστές της εκστρατείας του γνώριζαν ότι ακόμη και στο καλύτερο σενάριο, ο Ομπάμα θα μπορούσε πιθανότατα να μην είναι σε θέση να κερδίσει τις εκλογές με την υπάρχουσα βάση υποστηρικτών. Η εκστρατεία χρειαζόταν έναν τρόπο για να αυξήσει την υποστήριξη για τον Ομπάμα κάνοντας πιο αποτελεσματική χρήση των διαθέσιμων πόρων. Με την αξιοποίηση των Uplift μοντέλων έγινε δυνατό να εντοπιστούν τα άτομα που είναι πιθανόν να επηρεαστούν θετικά από τις διαφημίσεις, την αλληλογραφία, τις τηλεφωνικές κλήσεις και τις υπόλοιπες προσπάθειες προσέγγισης.

Ο Daniel Porter, ο άνθρωπος πίσω από τη στατιστική ομάδα του Ομπάμα θεώρησε πως λίγο πριν τη διαδικασία των εκλογών είναι ιδιαίτερα κρίσιμο η εκστρατεία να απευθυνθεί στους σωστούς ψηφοφόρους. Με την ομάδα των 8 αναλυτών της καμπάνιας του 2012 αναζήτησαν τους Persuadables, δηλαδή την ομάδα ψηφοφόρων που ενώ εκείνη τη στιγμή στρέφονταν προς την εκλογή Romney ήταν δυνατό να αλλάξουν γνώμη μετά από μία επαφή. Με αυτή την πληροφορία, η εκστρατεία του Ομπάμα μπόρεσε να εξοικονομήσει υλικούς και ανθρώπινους πόρους για την επικοινωνία με ψηφοφόρους που είχαν ήδη αποφασίσει να στηρίξουν τον τότε αντίπαλο του. Με την αξιοποίηση των Uplift μοντέλων προσδιορίστηκε ποιοι ψηφοφόροι είναι δεκτικοί και ποιοι όχι.

Για να το επιτύχει αυτό, η ομάδα του Porter διεξήγαγε πρώτα ένα πείραμα στο οποίο κάποιοι άνθρωποι κλήθηκαν (και κάποιοι όχι) σε μια παρουσίαση. Στη συνέχεια οι δύο ομάδες ρωτήθηκαν σχετικά με την υποστήριξη τους στον Ομπάμα και η διαφορά ήταν πέντε ποσοστιαίες μονάδες υπέρ του Treated γκρουπ, δηλαδή των ατόμων στα οποία πραγματοποιήθηκε οποιοδήποτε είδος επικοινωνία. Με βάση αυτά τα δεδομένα οι αναλυτές δημιούργησαν ένα μείγμα πολιτικής άποψης, δημογραφικών χαρακτηριστικών και άλλων δεδομένων για να αναπτύξουν μια σειρά από μοντέλα πρόβλεψης που βαθμολογούσαν κάθε ψηφοφόρο στις καίριες πολιτείες.

Μετά τις απαραίτητες δοκιμές και αναθεωρήσεις, οι τελικές εκδόσεις των μοντέλων χρησιμοποιήθηκαν τον Οκτώβριο του 2012. Σύμφωνα με τον Porter, κάθε χτύπημα πόρτας και κάθε τηλεφωνική κλήση ήταν πλήρως καθοδηγούμενα κατά τις τελευταίες εβδομάδες της προεκλογικής εκστρατείας. Επίσης, χρησιμοποιήθηκαν για τη στόχευση Persuadable ψηφοφόρων μέσω αλληλογραφίας, διαφήμισης στα μέσα κοινωνικής δικτύωσης και τηλεοπτικών διαφημίσεων. Τα μοντέλα επέτρεψαν στην εκστρατεία να προσεγγίσει ψηφοφόρους σε ατομικό επίπεδο με βάση το μήνυμα και τη μορφή επαφής στην οποία θα ήταν πιθανότεροι να είναι δεκτικοί.

Μεθοδολογία & Προσεγγίσεις του Uplift Modeling

3.1 Μεθοδολογία

Υπάρχουν τρεις προσεγγίσεις για τη μοντελοποίηση uplift. Οι πρώτες μοντελοποιούν τις απαντήσεις σε δύο ανεξάρτητες ομάδες, υπολογίζοντας στη συνέχεια τις διαφορές των πιθανοτήτων. Έτσι, το uplift διαμορφώνεται μόνο έμμεσα και ως εκ τούτου η βελτιστοποίηση δε βασίζεται σε αυτό. Τα όποια θετικά αποτελέσματα είναι μάλλον συγκυριακά καθώς δεν υπάρχει καμία εγγύηση ότι επιλέγονται οι ίδιες μεταβλητές και στα δύο μοντέλα. Έτσι, η προσέγγιση αυτή δεν μπορεί να ληφθεί σοβαρά.

Οι υπόλοιπες προσεγγίσεις βασίζονται σε ένα τυποποιημένο σύνολο δεδομένων το οποίο περιλαμβάνεται και στις δύο ομάδες. Η υπαγωγή της ομάδας διαμορφώνεται μέσω μιας δυαδικής μεταβλητής (0/1). Η δεύτερη προσέγγιση χρησιμοποιεί δέντρα απόφασης με ένα τροποποιημένο κριτήριο διαχωρισμού. Το κριτήριο αυτό αξιολογεί την αξία μιας ενδεχόμενης διάσπασης χρησιμοποιώντας τη διαφορά των κατανομών μεταβλητών απόκρισης μεταξύ των Test και Control γκρουπ. Σε αυτή τη διαδικασία, η διαφορά υπολογίζεται με τη βοήθεια της απόκλισης Kullback-Leibler μεταξύ της αντικειμενικής αναμενόμενης τιμής και της πραγματικής τιμής απόκρισης.

Αυτή η προσέγγιση με βάση τα δέντρα απόφασης έχει επίσης τις παγίδες της: εμμέσως υποθέτει ότι το κριτήριο διαχωρισμού μειώνεται σε ένα κανονικό κριτήριο σχισίματος εάν το μέγεθος της ομάδας ελέγχου είναι μηδέν, όπως στην περίπτωση των παραδοσιακών μοντέλων απόκρισης. Αυτό δεν έχει αποδειχθεί επισήμως αλλά στην πράξη η προσέγγιση αποδίδει χρήσιμα αποτελέσματα.

Η τρίτη προσέγγιση χρησιμοποιεί τη λογιστική παλινδρόμηση και έχει ως στόχο τις συνέπειες της αλληλεπίδρασης των μεταβλητών απόκρισης με τη μεταβλητή δείκτη για την υπαγωγή με την ομάδα ελέγχου. Ιδιαίτερη έμφαση δίνεται στην επιλογή των μεταβλητών. Κυρίως, η μεταβλητή απόκρισης αντικαθίσταται από μια ειδική σχέση μεταξύ της μεταβλητής απόκρισης και της μεταβλητής του γκρουπ. Αυτή η τροποποιημένη μεταβλητή λαμβάνει την τιμή 1 αν η απάντηση έχει ληφθεί και το σύνολο των δεδομένων ανήκει στο Test γκρουπ ή εάν καμία απάντηση δεν έχει ληφθεί και το σύνολο των δεδομένων ανήκει στο Control γκρουπ. Σε όλες τις άλλες περιπτώσεις, παίρνει την τιμή 0. Αυτό έχει το πλεονέκτημα ότι ανάλογα με το μέγεθος του Control γκρουπ, μπορεί να επιτευχθεί μια πιο ομοιογενής κατανομή της

μεταβλητής στόχου αντί της ρεαλιστικής κατανομής μεταξύ 1% και 3%. Σε αυτή τη διαδικασία, χρησιμοποιούνται κοινές μεταβλητές επιλογής. Το πραγματικό μοντέλο στη συνέχεια εκτιμάται με τη βοήθεια της αρχικής κωδικοποιημένης μεταβλητής στόχου.

3.2 Πως αξιολογούμε την απόδοση ενός μοντέλου;

Το έργο της αξιολόγησης των Uplift μοντέλων είναι δυσκολότερο σε σχέση με την παραδοσιακή μοντελοποίηση. Για ένα δεδομένο άτομο γνωρίζουμε μόνο ένα από τα αποτελέσματα, είτε μετά είτε χωρίς την επίδραση της ενέργειας. Ως εκ τούτου, δεν είναι δυνατό να γνωρίζουμε αν η ενέργεια είχε πραγματικό όφελος για το άτομο αυτό. Επίσης, δεν μπορούμε να εκτιμήσουμε τις επιδόσεις του μοντέλου στο επίπεδο των μεμονωμένων δεδομένων, αφού αυτό είναι δυνατό μόνο για ομάδες παρόμοιων δεδομένων. Υπενθυμίζουμε ότι η ανάπτυξη μοντέλων Uplift απαιτεί δύο σύνολα εκπαίδευσης. Κατά συνέπεια, έχουμε επίσης δύο σετ δοκιμής: της ενέργειας και ελέγχου. Μια τυπική προσέγγιση για την αξιολόγηση των μοντέλων [Radcliffe και Surry 2011, Hansotia & Rukstales 2002] είναι ο υπολογισμός και των δύο συνόλων δεδομένων δοκιμής χρησιμοποιώντας το ίδιο μοντέλο Uplift και υποθέτοντας ότι τα αντικείμενα στις ομάδες θεραπείας και ελέγχου που έχουν λάβει παρόμοιες βαθμολογίες είναι παρόμοια, άρα και μπορούν να συγκριθούν μεταξύ τους.

Σε μια έρευνα του Lo [2002], οι ερευνητές δημιούργησαν την ομάδα στόχου (treatment group) και την ομάδα ελέγχου και ανέλυσαν τα αποτελέσματα της παρέμβασης στα διαφορετικά δεκατημόρια (deciles) του βαθμού ανταπόκρισης των χρηστών (top-10%, 20% κλπ των περισσότερων ανταποκρινόμενων και αντίστοιχα για τα bottom-10%, 20% κλπ) και εκτίμησαν τα καθαρά κέρδη αφαιρώντας τα ποσοστά επιτυχίας κάθε δεκατημορίου. Μια πιο πρακτική τροποποίηση της προσέγγισης αυτής είναι η απεικόνιση της απόδοσης με τη χρήση Uplift καμπυλών [Rzepakowski & Jaroszewicz (2010), Radcliffe & Surry (2011)]. Ένα από τα εργαλεία για την αξιολόγηση της απόδοσης των παραδοσιακών μοντέλων ταξινόμησης είναι οι καμπύλες lift, όπου ο άξονας x αντιστοιχεί στον αριθμό των υποθέσεων που υποβάλλονται σε δράση και ο άξονας y στον αριθμό των επιτυχιών που αποτυπώνεται από το μοντέλο. Προκειμένου να ληφθεί μια Uplift καμπύλη έχουμε υπολογίσει και τα δύο σύνολα χρησιμοποιώντας το μοντέλο, αφαιρώντας στη συνέχεια την καμπύλη lift που δημιουργείται για τη δοκιμή ελέγχου από την καμπύλη που δημιουργείται για το σύνολο δοκιμή θεραπείας. Ο αριθμός των επιτυχιών και για τις δύο καμπύλες εκφράζεται ως ποσοστό του συνολικού πληθυσμού, έτσι ώστε η αφαίρεση να έχει νόημα.

Η ερμηνεία της καμπύλης Uplift γίνεται ως εξής: στον άξονα x επιλέγουμε το ποσοστό του πληθυσμού στο οποίο εκτελείται η δράση και στον άξονα y

παρατηρούμε το καθαρό κέρδος που επετεύχθη από την ομάδα στόχο (το καθαρό κέρδος για τις υπόλοιπες περιπτώσεις είναι μηδέν δεδομένου ότι καμία δράση δε διεξήχθη σε αυτά). Το σημείο $x = 100\%$ δίνει το κέρδος στην πιθανότητα επιτυχίας στην περίπτωση που η εφαρμοζόταν στο σύνολο του πληθυσμού. Μια διαγώνιος καμπύλη Uplift αντιστοιχεί στην εκτέλεση της δράσης για ένα τυχαία επιλεγμένο ποσοστό του πληθυσμού. [Rzepakowski & Jaroszewicz (2010), Radcliffe & Surry (2011)]. Όπως και με τις καμπύλες ROC, μπορούμε να χρησιμοποιήσουμε την περιοχή κάτω από την καμπύλη Προσαυξήσεων (AUUC) για να συνοψίσουμε τις επιδόσεις του μοντέλου με ένα μόνο αριθμό. Αφαιρούμε την περιοχή κάτω από τη διαγώνιο από την τιμή προκειμένου να αποκτήσουμε αριθμούς με μεγαλύτερο νόημα. Η περιοχή κάτω από την καμπύλη Uplift μπορεί να είναι μικρότερη από μηδέν, κάτι που συμβαίνει όταν το μοντέλο δίνει υψηλές βαθμολογίες στις περιπτώσεις για τις οποίες η δράση έχει κυρίως αρνητικές συνέπειες.

Για γίνει περισσότερο κατανοητό το πως αξιολογούμε την απόδοση ενός μοντέλου μπορούμε να χρησιμοποιήσουμε τον παρακάτω πίνακα:

	Ποσοστό Ανταπόκρισης για το Test Group	Ποσοστό Ανταπόκρισης για το Control Group	Uplift ποσοστού ανταπόκρισης
Επιλογή Μοντέλου	A	B	A - B
Τυχαία Επιλογή	C	D	C - D
Μέτρηση απόδοσης	Τα μοντέλα απόκρισης λειτουργούν μόνο αν $A > C$ και $B > D$		Το Uplift λειτουργεί αν $(A - B) > (C - D)$

Ένα καλό Response Model δε δημιουργεί πραγματικό Uplift.

3.3 Προκλήσεις στην εφαρμογή του Uplift Modeling

Όπως κάθε μοντέλο πρόβλεψης, έτσι και τα Uplift μοντέλα έχουν κάποιες προκλήσεις για την επιτυχή εφαρμογή τους. Καταρχάς, δεν μπορούν να απεικονίσουν ποιος από τους πελάτες παρουσιάζει αυξητική τάση, χαρακτηρίζονται ως incremental στη βιβλιογραφία, κάτι που άλλωστε αν το γνωρίζαμε εξ αρχής θα στρεφόμασταν στην παραδοσιακή λύση των μοντέλων απόκρισης.

Τα Uplift μοντέλα προσπαθούν να εντοπίσουν τους τεκμηριωμένα Incremental πελάτες μέσω δεύτερης ή και μεγαλύτερης τάξης τεχνικών μοντελοποίησης.

Άλλωστε, και η λογική του Incremental βασίζεται στην επίδραση μιας ενέργειας σε έναν αριθμό ατόμων. Αυτή η αλληλεπίδραση ακόμα και στην απλούστερη μορφή της είναι δεύτερης τάξης.

Μοντέλα αυτού του τύπου μπορούν να γίνουν ιδιαίτερα ασταθή στο πέρας του χρόνου, αφού είναι ιδιαίτερα ευάλωτα σε αλλαγές του περιβάλλοντος τους. Επίσης, ο υπολογισμός του Uplift γίνεται με τη χρήση μεταβλητών που δε συνηθίζονται στα συνήθη στατιστικά μοντέλα ενώ είναι απαραίτητες οι περισσότερες αναβαθμίσεις.

3.4 Εργαλεία

Η πραγματοποίηση στατιστικών αναλύσεων με το χέρι στην εποχή μας είναι πραγματικά περιττή. Σήμερα, υπάρχουν τρία βασικά προγράμματα για στατιστικές αναλύσεις:

- IBM SPSS
- SAS
- R

R

Η R είναι μια γλώσσα και περιβάλλον για στατιστικούς υπολογισμούς και γραφικά. Πρόκειται για ένα έργο που αναπτύχθηκε στα εργαστήρια Bell (πρώην AT & T, τώρα Lucent Technologies) από τον John Chambers και τους συναδέλφους του. Παρέχει μια μεγάλη ποικιλία στατιστικών - γραμμικών και μη γραμμικών μοντέλων, κλασική στατιστική, ανάλυση χρονοσειρών, ταξινόμηση, ομαδοποίηση - και είναι εξαιρετικά επεκτάσιμη.

Ένα από τα δυνατά σημεία της R είναι η ευκολία με την οποία μπορούν να παραχθούν ποιοτικές αναφορές, συμπεριλαμβανομένων μαθηματικών συμβόλων και τύπων αν κριθεί απαραίτητο. Είναι διαθέσιμη ως ελεύθερο λογισμικό υπό τους όρους της GNU General Public License του Ιδρύματος Ελεύθερου Λογισμικού σε μορφή πηγαίου κώδικα. Συντάσσεται και τρέχει σε μια ευρεία ποικιλία από πλατφόρμες UNIX και παρόμοιων συστημάτων, τα Windows και το MacOS.

IBM SPSS

Το SPSS είναι ένα ευρέως χρησιμοποιούμενο πρόγραμμα για στατιστική ανάλυση. Χρησιμοποιείται από αναλυτές της αγοράς, ερευνητές της υγείας, εταιρείες έρευνας, της κυβέρνησης, της εκπαίδευσης ερευνητών και άλλους. Το αρχικό εγχειρίδιο του SPSS (Nie et al, 1970) έχει χαρακτηριστεί ως ένα από τα σημαντικότερα βιβλία αφού

επέτρεψε σε απλούς ερευνητές να πραγματοποιήσουν τη δική τους στατιστική ανάλυση. Εκτός από τη στατιστική ανάλυση, η διαχείριση δεδομένων και η τεκμηρίωση τους είναι κύρια χαρακτηριστικά του.

Πακέτα στατιστικών που περιλαμβάνονται στο βασικό πακέτο:

- Descriptive statistics: Cross tabulation, Frequencies, Descriptives, Explore, Descriptive Ratio Statistics
- Bivariate statistics: Means, t-test, ANOVA, Correlation (bivariate, partial, distances), Nonparametric tests
- Prediction for numerical outcomes: Linear regression
- Prediction for identifying groups: Factor analysis, cluster analysis (two-step, K-means, hierarchical), Discriminant

Τα πολλά χαρακτηριστικά του SPSS είναι άμεσα προσβάσιμα ή μπορεί να προγραμματιστούν με μια γλώσσα σύνταξης εντολών. Η σύνταξη κώδικα έχει τα οφέλη της υψηλής παραγωγικότητας, της απλούστευσης επαναλαμβανόμενων εργασιών και το χειρισμό πολύπλοκων χειρισμών στοιχείων και αναλύσεων.

SAS

Το SAS είναι μια σουίτα λογισμικού που μπορεί να εξορύξει, να αλλάξει, να διαχειριστεί και να ανακτήσει δεδομένα από διάφορες πηγές εκτελώντας στατιστικές αναλύσεις. Παρέχει ένα γραφικό περιβάλλον για τους μη τεχνικούς χρήστες και πιο προηγμένες επιλογές μέσα από τη γλώσσα προγραμματισμού SAS.

Έρευνα

Μερικές φορές, ο ερευνητής πρέπει να χρησιμοποιήσει περισσότερα από ένα εργαλεία για να πραγματοποιήσει τις αναλύσεις του. Αυτό σημαίνει ότι οι χρήστες των προγραμμάτων πρέπει να μετακινηθούν από το ένα στο άλλο περιβάλλον, από το front-end στο back-end, χρησιμοποιώντας διαφορετικούς οδηγούς και γραφικά περιβάλλοντα σπαταλώντας στις περισσότερες περιπτώσεις ένα σημαντικό χρονικό διάστημα. Σε αυτό το κομμάτι θα αναλυθούν οι διαφορές μεταξύ των προαναφερθέντων προγραμμάτων, επισημαίνοντας τα πλεονεκτήματα και την πιο κατάλληλη χρήση κάθε λογισμικού.

Για μια καλή επιλογή ενός στατιστικού προγράμματος, πρέπει κανείς να λάβει υπόψη διάφορα ζητήματα όπως τα εξής:

- **Εμφάνιση:** Έχει να κάνει με το πως ο ερευνητής έχει συνηθίσει τη χρήση ενός συγκεκριμένου στατιστικού προγράμματος και δε χρειάζεται να μάθει κάτι καινούργιο.

- **Δυσπιστία στα δωρεάν λογισμικά:** λόγω του τρόπου με τον οποίο παρέχεται η υποστήριξη. Στην έλλειψη κάποιου συμβολαίου υποστήριξης ή συντήρησης δημιουργείται ανασφάλεια στη χρήση δωρεάν λογισμικών.
- **Διαθεσιμότητα στατιστικών μεθόδων:** Βρίσκονται οι πλέον διαδεδομένες στατιστικές μέθοδοι στη βιβλιοθήκη του εργαλείου;
- **Διαχείριση ογκωδών συνόλων δεδομένων:** Ένα πρόβλημα που αφορά οποιοδήποτε λογισμικό και κατ' επέκταση και ένα λογισμικό στατιστικής επεξεργασίας δεδομένων.

Εστιάζοντας στο πρώτο σημείο, είναι αξιοσημείωτο ότι ο προγραμματισμός με αυτά τα τρία εργαλεία είναι αρκετά εύκολος. Όλα τους άλλωστε, παρέχουν την επιλογή για σύνταξη κώδικα. Εκτός αυτού, το IBM SPSS και η R προσφέρουν ένα φιλικό περιβάλλον που αποτελεί εναλλακτική λύση για όσους δεν είναι εξοικειωμένοι με τη διαδικασία σύνταξης κώδικα. Αυτός είναι ένας από τους κύριους λόγους για τους οποίους οι ερευνητές συνεχίζουν να κάνουν ανάλυση των δεδομένων για μεγάλο χρονικό διάστημα με το ίδιο στατιστικό πρόγραμμα.

Ένα άλλο σημαντικό ζήτημα είναι κατά πόσον η διάθεση του εργαλείου είναι δωρεάν ή όχι. Όταν κάποιος αρχίσει να εργάζεται ως στατιστικός ερευνητής, σύντομα θα πρέπει να ανταπεξέλθει στο υψηλό κόστος άδειας χρήσης λογισμικού. Όπως είναι γνωστό, το IBM SPSS και το SAS αποτελούν εμπορικές διανομές ενώ η R είναι δωρεάν. Παρά το γεγονός ότι IBM SPSS και SAS είναι αρκετά ακριβά εργαλεία, θα πρέπει να υπολογίσουμε τα οφέλη που προσφέρουν μακροπρόθεσμα. Για παράδειγμα, ορισμένοι ερευνητές δεν εμπιστεύονται την R και θεωρούν πως η χρήση της δεν εξασφαλίζει τα σωστά αποτελέσματα. Αντίθετα από αυτές τις απόψεις, η R έχει αυξηθεί ραγδαία τα τελευταία χρόνια αποτελώντας ένα μεγάλο ανταγωνιστή.

Η διαθεσιμότητα των πλέον διαδεδομένων στατιστικών διαδικασιών και τεχνικών είναι ένα άλλο σημαντικό σημείο που πρέπει να ληφθεί υπόψη. Σε όλα τα εργαλεία έχουν ενσωματωθεί οι δημοφιλέστερες στατιστικές μέθοδοι (παλινδρόμηση, ανάλυση αλληλογραφίας κλπ), αλλά συχνά υπάρχει ανάγκη για την εφαρμογή πιο εξελιγμένων διαδικασιών. Τα IBM SPSS και SAS δεν επιτρέπουν στο χρήστη την παραμετροποίηση τους. Αντιθέτως, η R μπορεί να νοηθεί ως ένα συνδυασμένο και προσαρμοσμένο λογισμικό για την επίλυση προβλημάτων. Όταν ο ερευνητής αντιμετωπίζει κάποιο πρόβλημα, το πιθανότερο είναι ότι θα μπορέσει να βρει τη λύση στη βιβλιοθήκη του εργαλείου.

Τέλος, όσον αφορά τη διαχείριση τεράστιων συνόλων δεδομένων, το SAS είναι ο νικητής. Πρόκειται για μια ισχυρή πλατφόρμα στο χειρισμό μεγάλων συνόλων δεδομένων που δεν απαιτεί το σύνολο της μνήμης του υπολογιστή για την ανάλυση τους. Σε αυτόν τον τομέα, η R έχει ακόμα πολύ δρόμο να διανύσει αν και η απόδοση της έχει πρόσφατα αυξηθεί εκθετικά. Από την άλλη, το IBM SPSS δε λαμβάνει την απαιτούμενη υποστήριξη.

A/B Testing και δοκιμή πολλαπλών παραλλαγών

Είναι σπάνια η περίπτωση να υπάρχουν ένα control και ένα treated group. Συχνά, το treated μπορεί να είναι μια ποικιλία από απλές παραλλαγές ενός μηνύματος ή μιας στρατηγικής πολλαπλών σταδίων που έχει χαρακτηριστεί ως ενιαία θεραπεία. Στην περίπτωση του A/B (δοκιμές πολλών μεταβλητών), το Uplift μπορεί να βοηθήσει στην κατανόηση για το αν οι διακυμάνσεις στις δοκιμές παρέχουν σημαντικό Uplift σε σύγκριση με άλλα κριτήρια στόχευσης, όπως η συμπεριφορά ή οι δημογραφικοί δείκτες.

3.5 Πλεονεκτήματα

Όπως αναφέρθηκε σε προηγούμενη ενότητα, τα Uplift μοντέλα συμβάλουν στη μεγιστοποίηση του ROI των εκστρατειών marketing, μειώνοντας τις επαφές με πελάτες που είναι ήδη εξαιρετικά πιθανό να αγοράσουν ένα προϊόν ή μια υπηρεσία. Τα παραδοσιακά μοντέλα μπορεί να πετυχαίνουν την κατάταξη των πελατών με βάση την πιθανότητα να πραγματοποιήσουν μια αγορά, αλλά δεν έχουν τη δυνατότητα να επιλέξουν εκείνους που ανταποκρίθηκαν πραγματικά, δηλαδή τους πελάτες που θα κάνουν μια αγορά μετά την επαφή. Τα μοντέλα εμπεριέχουν προκλήσεις συνδυάζοντας τα αποτελέσματα δύο ξεχωριστών μοντέλων, για το λόγο αυτό ο ερευνητής θα πρέπει να ακολουθήσει τις παρακάτω προϋποθέσεις για την επιτυχή εφαρμογή τους:

- Ένα τυχαία παραγόμενο Control Group
- Η επαφή μετά την ανάλυση δεν είναι η μόνη επικοινωνία που οδηγεί σε αγορά
- Απαραίτητη προϋπόθεση η παρουσία παρόμοιων προηγούμενων ενεργειών

Η ευελιξία των Uplift μοντέλων καθιστά ευκολότερη τη δοκιμή και τον εντοπισμό σφαλμάτων σε σύγκριση με άλλα μοντέλα. Δεδομένου ότι πραγματοποιούνται μικρές αλλαγές σε κάθε φάση, οι ερευνητές μπορούν να στοχεύσουν και να πειραματιστούν στο ευρύτερο πλαίσιο της εφαρμογής του μοντέλου. Με τα Uplift μοντέλα μειώνεται δραστικά το αρχικό κόστος παράδοσης ενώ τα οφέλη της εφαρμογής τους μπορεί να παρατηρήσει κανείς σε ένα ευρύ σύνολο εφαρμογών:

- Παραγωγή περισσότερων απαντήσεων από κατάλληλα στοχευμένες εκστρατείες marketing
- Απομόνωση των ατόμων που θα επωφεληθούν από τις εκστρατείες διατήρησης
- Στόχευση του σωστού ασθενή σε κλινικές δοκιμές
- Επιπλέον ψήφοι από τη στόχευση των κατάλληλων ομάδων σε προεκλογικές εκστρατείες πολιτικών

3.6 Αρνητικές επιπτώσεις

Μία από τις πιο αποτελεσματικές χρήσεις των Uplift μοντέλων είναι η απομάκρυνση των αρνητικών επιπτώσεων από τις καμπάνιες. Τόσο στον τομέα των τηλεπικοινωνιών, όσο και σε εκείνον των χρηματοπιστωτικών υπηρεσιών οι συχνές εκστρατείες διατηρησιμότητας μπορούν να προκαλέσουν τους πελάτες με αποτέλεσμα να ακυρώσουν μια σύμβαση ή το συμβόλαιο τους. Με τα Uplift μοντέλα είναι δυνατό αυτοί οι πελάτες να αφαιρεθούν από την εκστρατεία.

Η πιθανή παρουσία αρνητικών επιπτώσεων είναι ένας ισχυρός λόγος για να εξεταστούν τα Uplift μοντέλα σοβαρά. Τα συμβατικά μοντέλα δεν είναι σε θέση να χειριστούν αρνητικές επιπτώσεις και αυτές είναι διπλά επιβλαβείς, από το γεγονός ότι φέρουν το κόστος της ενέργειας ενώ μειώνουν το συνολικό αντίκτυπο της δραστηριότητας. Δεν είναι ασυνήθιστο, ιδίως στον τομέα της διατήρησης πελατών, τα Uplift μοντέλα να προσδώσουν αξία στην αναγνώριση των πληθυσμών όπου οι αρνητικές επιπτώσεις είναι διαδεδομένες σε σχέση με τα τμήματα πληθυσμού και ο αντίκτυπος είναι ουδέτερος ή θετικός. Αρνητικές επιπτώσεις τείνουν να εμφανίζονται περισσότερο όταν το Uplift είναι μικρό, όπου η αδράνεια από την πλευρά του πελάτη οδηγεί σε μια θετική έκβαση για τον προμηθευτή, όπου οι παρεμβάσεις είναι ενοχλητικές, και όπου οι πελάτες είναι ήδη δυσαρεστημένοι με τον προμηθευτή. Αυτός είναι ο λόγος που τα Uplift μοντέλα χρησιμοποιούνται ευρέως και είναι πιο αποτελεσματικά σε στρατηγικές διατήρησης πελατών.

Αξιοσημείωτες αποτυχίες

Η προγνωστική μοντελοποίηση είναι μια μεθοδολογία που έχει χρησιμοποιηθεί ευρέως στον χρηματοοικονομικό κλάδο κατά το παρελθόν και μερικές από τις θεαματικές αποτυχίες συνέβαλαν στην οικονομική κρίση του 2008. Αυτές οι αποτυχίες εξηγούν γιατί η τυφλή εξάρτηση σε μοντέλα μπορεί να αποτελέσει μεγάλο κίνδυνο. Τα παρακάτω παραδείγματα δεν αποτελούν σε καμία περίπτωση μια πλήρη λίστα αλλά είναι ενδεικτικά του κινδύνου:

- S & P, Moody και Fitch: η ποσοτικοποίηση της πιθανότητας αθέτησης των ομολόγων με διακριτές μεταβλητές ονομάζεται βαθμολόγηση. Η βαθμολογία μπορεί να πάρει διακριτές τιμές από AAA ως D. Πρόκειται για έναν προγνωστικό δείκτη του κινδύνου αθέτησης και βασίζεται σε μια ποικιλία μεταβλητών που συνδέονται με τον δανειολήπτη και μακρο-οικονομικά δεδομένα που αντλούνται από τα ιστορικά. Οι οργανισμοί αξιολόγησης απέτυχαν θεαματικά με τις αξιολογήσεις τους για τα 600 δισεκατομμύρια δολάρια ενυπόθηκων CDO. Σχεδόν το σύνολο του τομέα AAA (και ο τομέας των σούπερ-AAA, μια νέα αξιολόγηση για τις σούπερ ασφαλείς επενδύσεις) της αγοράς CDO υποβαθμίστηκε σοβαρά κατά τη διάρκεια του 2008, με πολλές από τις όποιες αξιολογήσεις να έχουν πραγματοποιηθεί λιγότερο από ένα χρόνο πριν.

- Στατιστικά μοντέλα που επιχειρούν να προβλέψουν τις τιμές της αγοράς μετοχών με βάση τα ιστορικά δεδομένα. Μέχρι στιγμής, δεν υπάρχει τέτοιο μοντέλο που να πραγματοποιεί σωστές προβλέψεις μακροπρόθεσμα. Μια αξιοσημείωτη αποτυχία είναι εκείνη του Long Term Capital Management, ενός ταμείου που προσέλαβε εξειδικευμένους αναλυτές, συμπεριλαμβανομένου ενός νικητή του βραβείου Νόμπελ στα οικονομικά, για να αναπτύξει ένα εξελιγμένο στατιστικό μοντέλο με σκοπό την πρόβλεψη τιμής μεταξύ των διαφόρων τίτλων. Τα μοντέλα που σχεδιάστηκαν είχαν εντυπωσιακά κέρδη έως ότου μια θεαματική καταστροφή που προκάλεσε τον τότε πρόεδρο του Federal Reserve, Alan Greenspan, να παρέμβει για να μεσολαβήσει ένα σχέδιο διάσωσης από τους χρηματιστές της Wall Street προκειμένου να αποφευχθεί η κατάρρευση της αγοράς ομολόγων.

Εκτίμηση κόστους / οφέλους

Αν και η τεχνική είναι σχετικά παλιά, οι πρώτες δημοσιεύσεις παρουσιάστηκαν το 1999, δεν υπάρχει μεγάλη βιβλιογραφία σχετικά με αυτή. Ειδικότερα, η αξιολόγηση από άποψη κόστους / οφέλους δεν είναι προφανής, κάτι που θέλει να εξετάσει αυτή η εργασία.

Ως συμπέρασμα της ανάλυσης κέρδους μπορεί κανείς να συμπεράνει ποια σενάρια έχουν σημασία για την Uplift μοντελοποίηση σε σύγκριση με ένα παραδοσιακό μοντέλο σχετικά με το κέρδος για την επιτυχή ανταπόκριση, το κόστος της στόχευσης και το κόστος μίας ανεπιτυχούς απάντησης. Για να κάνει το μοντέλο μια μεγάλη διαφορά, ίσως να χρειάζεται ένα σενάριο με σχετικά υψηλό κόστος στόχευσης. Αν ληφθεί υπόψη το γεγονός ότι θα πρέπει ιδανικά να πραγματοποιηθεί ένα πείραμα A/B για τη λήψη των δεδομένων εκπαίδευσης, το κύριο συμπέρασμα είναι ότι η ανάλυση κόστους/κέρδους γίνεται ακόμα πιο σημαντική από ότι συνήθως.

4.1 Project

Στο κεφάλαιο αυτό θα παρουσιαστεί η διαδικασία της εφαρμογής ενός μοντέλου Uplift σε πραγματικά δεδομένα. Η εφαρμογή αφορά την πρόκληση που τέθηκε στο Blog MinethatData² στις 20 Μαρτίου του 2008 χρησιμοποιώντας τα εξής στοιχεία:

Το σύνολο δεδομένων περιέχει 64.000 πελάτες που πραγματοποίησαν τουλάχιστον μια αγορά τους προηγούμενους 12 μήνες. Συγκεκριμένα:

- 1/3 επιλέχθηκαν τυχαία για να λάβουν μια εκστρατεία ηλεκτρονικού ταχυδρομείου σχετικά με αντρικά εμπορεύματα
- 1/3 επιλέχθηκαν τυχαία για να λάβουν μια εκστρατεία ηλεκτρονικού ταχυδρομείου σχετικά με γυναικεία εμπορεύματα
- 1/3 επιλέχθηκαν τυχαία να μην λάβουν καμία εκστρατεία ηλεκτρονικού ταχυδρομείου

² <http://blog.minethatdata.com/2008/03/minethatdata-e-mail-analytics-and-data.html>

Καμπάνια	Αντρικά	Γυναικεία	Καμία	Σύνολο
Αριθμός	21.307	21.387	21.306	64.000
Ποσοστό	33,29%	33,42%	33,29%	100%

Τα χαρακτηριστικά του συνόλου δεδομένων είναι τα εξής:

- **Recency:** Μήνες από την τελευταία αγορά
- **History_Segment:** Κατηγοριοποίηση των χρημάτων που ξοδεύτηκαν το περασμένο έτος
- **History:** Ακριβές ποσό που ξοδεύτηκε το περασμένο έτος
- **Mens:** Δυαδική ένδειξη, την τιμή 1 λαμβάνουν όσοι πελάτες αγόρασαν αντρικά εμπορεύματα
- **Womens:** Δυαδική ένδειξη, την τιμή 1 λαμβάνουν όσοι πελάτες αγόρασαν γυναικεία εμπορεύματα
- **Zip_Code:** Κατηγοριοποίηση ταχυδρομικού κώδικα σε αστική, επαρχιακή ή αγροτική περιοχή
- **Newbie:** Δυαδική ένδειξη, την τιμή 1 λαμβάνουν οι νέοι πελάτες των τελευταίων 12 μηνών
- **Channel:** Περιγραφή των καναλιών από όπου πραγματοποιήθηκαν οι αγορές

Μια ακόμα μεταβλητή περιγράφει ποια καμπάνια ηλεκτρονικού ταχυδρομείου έλαβε ο πελάτης:

- **Καμπάνια για αντρικά εμπορεύματα**
- **Καμπάνια για γυναικεία εμπορεύματα**
- **Καμία καμπάνια**

Υπάρχει ακόμα μια ομάδα μεταβλητών που περιγράφει τη δραστηριότητα των πελατών 2 εβδομάδες μετά την αποστολή του μηνύματος:

- **Visit:** Δυαδική ένδειξη, την τιμή 1 λαμβάνουν οι πελάτες που επισκέφθηκαν την ιστοσελίδα εντός 2 εβδομάδων
- **Conversion:** Δυαδική ένδειξη, την τιμή 1 λαμβάνουν οι πελάτες που πραγματοποίησαν αγορά εντός 2 εβδομάδων

- **Spend:** Το συνολικό ποσό που ξοδεύτηκε εντός 2 εβδομάδων

Κατά τη διάρκεια των δύο εβδομάδων από την αποστολή των ηλεκτρονικών μηνυμάτων, παρακολουθούνται τα αποτελέσματα. Η δουλειά του ερευνητή είναι να αξιολογήσει για το ποια ενέργεια ήταν επιτυχής. Για την πρόκληση τέθηκαν αρκετά ερωτήματα μερικά από τα οποία είναι:

- Ποια είναι η σταδιακή ανταπόκριση των πελατών για οποιαδήποτε από τις δύο καμπάνιες;
- Είναι ένας τρόπος για να επιλέξετε τον καλύτερο τρόπο ένα υποσύνολο των πελατών που θα πρέπει οριστικά να έχουν ως στόχο (δηλαδή θα απαντήσει πιθανότατα σε μια ενέργεια) εκεί;
- Τι θα γίνει με ένα υποσύνολο των πελατών που θα μπορούσαν να αφαιρεθούν από τις εκστρατείες (δεδομένου ότι θα μετατρέψει έτσι κι αλλιώς);

Για τα περισσότερα από τα παραπάνω θεωρούμε ότι η θετική ανταπόκριση σημαίνει πραγματικά μετατροπή, δηλαδή αγορά.

Το εργαλείο που θα χρησιμοποιήσουμε είναι το ελεύθερης διανομής λογισμικό **R** μαζί με το πακέτο **Uplift**. Αρχικά δημιουργούμε μια νέα στήλη που θα υποδείξει εάν ο πελάτης ανήκει στο **Control group** ή όχι και να μετατρέψει σε παράγοντες μερικά χαρακτηριστικά με λογικές τιμές 0/1. Το πακέτο περιέχει πολλές χρήσιμες λειτουργίες για τη μοντελοποίηση, στην περίπτωση μας η λειτουργία **rvtu** μετατρέπει το σύνολο δεδομένων για να δημιουργήσει μια νέα μεταβλητή που θα δείξει, όταν χρησιμοποιηθεί από έναν ταξινομητή, την αυξητική πιθανότητα μετατροπής. Δηλαδή, την πιθανότητα ο πελάτης να πραγματοποιήσει αγορά αφού στοχευθεί μείον την πιθανότητα να αγοράσει χωρίς πρώτα να έχει στοχευθεί.

Δημιουργούμε τη μεταβλητή που λείπει για αυτή την πιθανότητα, λαμβάνοντας υπόψη το γεγονός ότι ο τύπος πρέπει να περιλαμβάνει τη στήλη για τη διάκριση των μητρώων ελέγχου σε αριθμητική μορφή (δημιουργήθηκε προηγουμένως) καθώς και κάθε στήλη που ο ταξινομητής θα χρησιμοποιηθεί αργότερα. Επίσης, επιλέγουμε τα δεδομένα για τον έλεγχο και την εκστρατεία **Womens E-Mail**, δεδομένου ότι έχει μεγαλύτερη επίδραση και έχει επίσης χρησιμοποιηθεί σε άλλη δημοσίευση. Για τον ίδιο λόγο, οι επισκέψεις στην ιστοσελίδα θεωρούνται ως μετατροπές.

Οι στήλες του συνόλου δεδομένων μετά τη μετατροπή:

## [1] "recency"	"history_segment"	"history"
## [4] "mens"	"womens"	"zip_code"

```
## [7] "newbie"      "channel"      "ct"
## [10] "y"           "z"
```

Προστέθηκαν:

- y ο αρχικός στόχος, π.χ η μετατροπή (αντικατέστησε τη στήλη visit)
- z η μετατροπή του Uplift Classifier που χρησιμοποιήθηκε για τον υπολογισμό της πιθανότητας μετατροπής
- ct με την τιμή 1 για τους πελάτες στόχο και 0 για τον έλεγχο

Για τη διερευνητική ανάλυση υπάρχει ακόμα μια χρήσιμη λειτουργία στο πακέτο, η **explore**, η οποία δίνει μια αριθμητική περίληψη της μετατροπής (δηλαδή του uplift) με βάση την αξία κάθε χαρακτηριστικού. Ο μόνος αριθμός που λείπει είναι το συνολικό uplift.

Τα αποτελέσματα που εξάγονται συνοψίζονται, δίνοντας μια πρώτη εικόνα για το uplift και τις ομάδες ατόμων που αξίζει να ασχοληθούμε. Παρατηρούμε για την καμπάνια συνολικά πως αξίζει να ασχοληθούμε με τους πελάτες που πραγματοποίησαν μια αγορά μεταξύ των τελευταίων 5 και 9 μηνών [Πίνακας 1] και με όσους ξοδεύουν περισσότερα από 500\$ [Πίνακας 2]. Το τελευταίο αποτυπώνεται και στον Πίνακα 3 αφού το μεγαλύτερο uplift παρουσιάζεται στην υψηλότερη κατηγορία.

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
[1,2]	5502	5481	0.1419	0.1885	0.0465
(2,5]	5174	5201	0.1165	0.1523	0.0357
(5,9]	6227	6184	0.0851	0.1389	0.0538
(9,12]	4403	4521	0.0790	0.1225	0.0435

Μεταβλητή: Recency (Πίνακας 1)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
\$0 - \$100	7612	7634	0.0849	0.1316	0.0468
\$100 - \$200	4836	4727	0.0910	0.1335	0.0425
\$200 - \$350	4044	4155	0.1264	0.1625	0.0361
\$350 - \$500	2124	2188	0.1502	0.1906	0.0404
\$500 - \$750	1652	1662	0.1096	0.1757	0.0661
\$750 - \$1,000	622	593	0.1543	0.2091	0.0548
\$1,000 +	416	428	0.1659	0.2196	0.0538

Μεταβλητή: History_Segment (Πίνακας 2)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
[30,65.2]	5319	5355	0.0846	0.1296	0.0450
(65.2,158]	5411	5262	0.0839	0.1300	0.0461
(158,326]	5262	5411	0.1203	0.1591	0.0388
(326,3.35e +03]	5314	5359	0.1364	0.1864	0.0500

Μεταβλητή: History (Πίνακας 3)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
0	9519	9647	0.0958	0.1698	0.0740
1	11787	11740	0.1145	0.1363	0.0218

Αποτελέσματα για την καμπάνια σχετικά με τα αντρικά εμπορεύματα (Πίνακας 4)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
0	9638	9622	0.0998	0.1109	0.0111
1	11668	11765	0.1114	0.1845	0.0731

Αποτελέσματα για την καμπάνια σχετικά με τα γυναικεία εμπορεύματα (Πίνακας 5)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
Rural	3139	3181	0.1536	0.1826	0.0291
Suburban	9625	9650	0.0990	0.1479	0.0489
Urban	8542	8556	0.0968	0.1438	0.0469


Μεταβλητή: Zip_code (Πίνακας 6)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
0	10611	10624	0.1337	0.1739	0.0401
1	10695	10763	0.0788	0.1292	0.0504

Αποτελέσματα για την καμπάνια σχετικά με τους νέους πελάτες (Πίνακας 7)

	N(Treat=0)	N(Treat=1)	Mean Resp.(Treat=0)	Mean Resp.(Treat=1)	Uplift
Multichann el	2606	2579	0.1285	0.1756	0.0471
Phone	9327	9454	0.0872	0.1318	0.0446
Web	9373	9354	0.1189	0.1645	0.0457


Μεταβλητή: Channel (Πίνακας 8)



Παραγώμενο γράφημα από την R

Το παραπάνω γράφημα αποτελεί μια σύγκριση της εκστρατείας για 3 τύπους μετατροπής (επίσκεψη στην ιστοσελίδα, πραγματική αγορά ή μετατροπή, καθώς και τα χρήματα που δαπανώνται) που σχετίζονται με τη στήλη recency (χρόνος που έχει παρέλθει από την τελευταία αγορά). Παρόμοια παραδείγματα μπορούν να χρησιμοποιηθούν και για τα υπόλοιπα των χαρακτηριστικά.

Ορίζουμε τον ταξινομητή με τη χρήση λογιστικής παλινδρόμησης (logistic regression). Υπάρχουν λόγοι για την απόφαση αυτή: είναι σχετικά γρήγορη και απλή στο να εφαρμοστεί ενώ επιτρέπει τη διασταρούμενη αξιολόγηση, συνήθως συμπεριφέρεται καλά και δίνει μια καλή προσέγγιση της πραγματικής πιθανότητας ενός πελάτη να ανήκει σε μια κατηγορία. Είναι επίσης δυνατό να ερμηνευθούν τα αποτελέσματα.



Σχήμα 4, Πηγή: Lo, V. , *The True Lift Model: A Novel Data Mining Approach to Response Modeling in Database Marketing*


Ωστόσο, στη βιβλιογραφία σχετικά με τα Uplift μοντέλα οι ερευνητές χρησιμοποιούν δέντρα απόφασης τις περισσότερες φορές. Στην πραγματικότητα, τα περισσότερα από τα έγγραφα τροποποιούν το τρόπο που δημιουργούνται τα δέντρα έτσι ώστε να βελτιστοποιείται η μοντελοποίηση. Τέτοιες περιπτώσεις για το σύνολο δεδομένων είναι η νικητήρια συμμετοχή του Radcliffe [2008] και η πρόταση των Piotr Rzepakowski και Szymon Jaroszewicz [2012].

4.2 Αποτελέσματα

Είναι η εφαρμογή ενός τέτοιου μοντέλου αποτελεσματική; Ας προσπαθήσουμε να το αξιολογήσουμε από τη μεριά της επιχείρησης.

Για την εκτίμηση του μοντέλου υπάρχουν αρκετές και αποδεκτές αναφορές από τον N. J. Radcliffe [2007, 2011]. Στην περίπτωση μας θα ακολουθήσουμε τον ορισμό

των καμπυλών Qini και της μεθόδου τους για υπολογισμό του κέρδους της καμπάνιας.



Στο παραπάνω σχήμα:


- Η κόκκινη καμπύλη αντιπροσωπεύει τις μετατροπές όταν οι πελάτες επιλέγονται τυχαία (χωρίς ταξινομητή)
- Η μπλε καμπύλη αντιπροσωπεύει τις μετατροπές με τη σειρά που ορίζονται από τον ταξινομητή

Η περιοχή κάτω από την μπλε καμπύλη και πάνω από την κόκκινη πρέπει να είναι η μεγαλύτερη δυνατή. Αυτό σημαίνει ότι ο ταξινομητής λειτουργεί σωστά για τους πελάτες και σύμφωνα με την πιθανότητα της μετατροπής: δηλαδή για μια μεγάλη περιοχή στοχεύοντας ένα μικρό ποσοστό πελατών θα φέρει μεγάλα κέρδη. Αν στοχευθεί το 100% των πελατών, το αναμενόμενο ποσοστό μετατροπής είναι περίπου 12%, ανεξάρτητα της μεθόδου.

Αυτή η αθροιστική καμπύλη απόκρισης είναι τεχνική, με την έννοια ότι αξιολογεί μόνο την ακρίβεια του ταξινομητή. Δεν αναφέρει τίποτα για το κέρδος της εκστρατείας, ούτε για το βέλτιστο ποσοστό των πελατών που θα πρέπει να στοχευθούν.

Από την άλλη πλευρά, εκτιμάται ότι η ακρίβεια του παραδοσιακού ταξινομητή είναι τουλάχιστον αξιοπρεπής.

Η παρακάτω καμπύλη είναι η Qini για τον Uplift ταξινομητή. Συσσωρεύει τον αριθμό των μετατροπών για τους πελάτες που έχουν στοχευθεί, χωρίς να περιλαμβάνει τους πελάτες του Test γκρουπ.



Σε αυτό το σχήμα:

- Ξανά η κόκκινη καμπύλη αντιπροσωπεύει τον τυχαίο ταξινομητή
- Η μπλε καμπύλη αντιπροσωπεύει τις μετατροπές με τη σειρά που ορίζονται από τον uplift ταξινομητή
- Η μαύρη καμπύλη αντιπροσωπεύει τον ιδανικό τρόπο απεικόνισης των πελατών. Όλοι οι πελάτες που μετατρέπουν επειδή στοχεύθηκαν (πρώτη γραμμή αριστερά), έπειτα οι πελάτες που δε μετέτρεψαν (ευθεία) και τέλος όλοι οι πελάτες που μετατρέπουν ακόμα και αν δε στοχευθούν (δεύτερη γραμμή δεξιά).

Και σε αυτήν την περίπτωση, όσο μεγαλύτερη είναι η περιοχή κάτω από την μπλε καμπύλη και πάνω από την κόκκινη, τόσο το καλύτερο, διότι αυτό σημαίνει ότι ο ταξινομητής λειτουργεί σωστά για τους πελάτες και σύμφωνα με την αυξητική πιθανότητα μετατροπής. Έτσι, για μια μεγάλη περιοχή με στόχο ένα μικρό ποσοστό πελατών θα επιστρέψει μεγαλύτερα κέρδη.

Αν στοχευθεί το 100% των πελατών, ο συνολικός αριθμός της μετατροπής θα είναι

και πάλι η βασική γραμμή του 12%, η αυξητική μετατροπή είναι γύρω στο 5%. Το 15% των στοχευμένων πελατών πραγματοποιεί αγορά αλλά περίπου 10% στο Control γκρουπ θα αγοράσει ούτως ή άλλως χωρίς στόχευση.

Πως συγκρίνονται οι δύο καμπύλες;

Όταν προσπαθήσουμε να αναλύσουμε την αυξητική τάση των εκστρατειών, ο όγκος των δεδομένων είναι ένα πραγματικό πρόβλημα όπου υπάρχει δυσκολία ακόμη και της διαμόρφωσης αξιόπιστων εκτιμήσεων για τις συνολικές επιπτώσεις.

Από αυτές τις δύο καμπύλες, δεν υπάρχει κανένας τρόπος για να αποφασίσουμε μεταξύ των παραδοσιακών μοντέλων και της Uplift μοντελοποίησης. Φυσικά, κατά τη δημιουργία της καμπύλης Qini για τον παραδοσιακό ταξινομητή, τα αποτελέσματα είναι χειρότερα σε σχέση με το Uplift ενώ διεγείρεται το εξής ερώτημα: το πραγματικό σενάριο των επιχειρήσεων εκφράζεται καλύτερα από την Qini καμπύλη; Αν κάποιος ανησυχεί για το υψηλό κόστος στόχευσης (π.χ. έκπτωση ή προσφορά, όταν απευθύνονται στους πελάτες) ή για τα **Sleeping Dogs** (πελάτες που έχουν μικρότερη πιθανότητα μετατροπής), τότε το Uplift μοντέλο και η καμπύλη Qini συμπεριφέρονται καλύτερα.

Συμπεράσματα - Μελλοντικά βήματα

Τα Uplift μοντέλα είναι σχεδόν πάντα, από θεωρητική σκοπιά, ο σωστός τρόπος για να διαμορφωθεί ένα marketing μοντέλο, κάτι που αποδεικνύεται και στην πράξη αφού παράγουν καλύτερα αποτελέσματα δικαιολογώντας την επιπλέον πολυπλοκότητα τους. Ωστόσο, όπως αναφέραμε και σε προηγούμενη ενότητα είναι απαραίτητη η ύπαρξη ενός έγκυρου Control γκρουπ.

Εκτός της ίδιας της ύπαρξης του Control γκρουπ, απαραίτητο είναι να έχει και το ανάλογο μέγεθος. Ένας γενικός κανόνας είναι ότι Control γκρουπ πρέπει να είναι τουλάχιστον δέκα φορές μεγαλύτερο για τη μοντελοποίηση από ό,τι για την απλή μέτρηση της αυξητικής τάσης. Ένας δεύτερος κανόνας είναι ότι για τη μοντελοποίηση δυαδικών αποτελεσμάτων, κάθε πληθυσμός θα πρέπει να έχει τουλάχιστον 500 άτομα. Από την άλλη, σε περίπτωση που ο πελάτης υπόκειται σε πολλές ενέργειες (διαφήμιση, πολλαπλές επικοινωνίες κλπ), ο κίνδυνος να αποδοθούν οι πωλήσεις εσφαλμένα σε ένα συγκεκριμένο κομμάτι της εμπορικής δραστηριότητας είναι μεγαλύτερος από ό,τι όταν υπάρχουν λιγότερες.

Μια κατάσταση που βλέπουμε συνήθως σε περιβάλλοντα λιανικής πώλησης είναι ότι οι άμεσες εμπορικές καμπάνιες Marketing φαίνεται να έχουν θετικότερη επίδραση σε πελάτες που ξοδεύουν περισσότερα. Όταν αυτό συμβαίνει, Uplift και πωλήσεις συσχετίζονται και ως εκ τούτου ένα συμβατικό μοντέλο και ένα μοντέλο Uplift είναι πιθανότερο να κατατάξουν τον πληθυσμό με παρόμοιους τρόπους.


Μια άλλη περίπτωση στην οποία μπορεί κάλλιστα να παραπλανηθεί η παραδοσιακή μοντελοποίηση είναι όταν το ποσοστό απόκρισης από προηγούμενες ενέργειες είναι υψηλό. Ως ένα ακραίο παράδειγμα, η πραγματοποίηση μιας ενέργειας σε έναν τακτικό εβδομαδιαίο πελάτη και στη συνέχεια μια αγορά του την επόμενη εβδομάδα να λαμβάνεται ως μετατροπή είναι μάλλον παράλογο. Από την άλλη πλευρά, μια σχετικά άγνωστη και μικρή εταιρεία λιανικής που στοχεύει σε άτομα που είναι απίθανο να έχουν ακούσει για αυτήν ή το προϊόν της θα μπορούσε να είναι πιο σίγουρη ότι οι απαντήσεις παρουσιάζουν αυξητική τάση ακόμη και χωρίς ομάδα ελέγχου. Σε τέτοιες περιπτώσεις μάλιστα, ένα Uplift μοντέλο μπορεί να προσφέρει ελάχιστο ή και κανένα όφελος.

5.1 Τα Uplift μοντέλα λειτουργούν πραγματικά;

Η Uplift μοντελοποίηση μπορεί να λειτουργήσει και έχει αποδειχθεί με δοκιμές στην αγορά και την ιατρική. Τα μοντέλα ωστόσο είναι δυσκολότερο να αναπτυχθούν σε σχέση με τα συμβατικά μοντέλα, επειδή προβλέπουν ένα αποτέλεσμα δεύτερης τάξης - συνήθως τη διαφορά μεταξύ δύο πιθανοτήτων. Αυτό σημαίνει ότι τα σφάλματα τείνουν να είναι μεγαλύτερα από τα συμβατικά μοντέλα και μερικές φορές οι υπάρχουσες τεχνικές δεν προσφέρουν την απαραίτητη ακρίβεια. Αυτό ισχύει ιδιαίτερα όταν το Control γκρουπ είναι μικρό.

Ωστόσο, η ιδέα της Uplift μοντελοποίησης γίνεται όλο και πιο δημοφιλής. Σύμφωνα με το παρακάτω γράφημα από την Gartner που δημοσιεύθηκε τον Ιούλιο του 2015, παρατηρούμε ότι ήδη θεωρείται καινοτομία και πρόκειται να φτάσει στο "Οροπέδιο της Παραγωγικότητας" σε ένα διάστημα 5 έως 10 ετών.

Figure 1. Hype Cycle for Advanced Analytics and Data Science, 2015



Source: Gartner (July 2015)

Σχήμα 5, Πηγή: Gartner, 2015 Hype Cycle for Advanced Analytics and Data Science

5.2 Η κατάσταση σήμερα

Σύμφωνα με την Gartner, το μοντέλο έχει υιοθετηθεί από 3% έως 5% μέχρι σήμερα. Αξιοποιείται κυρίως στις χρηματοπιστωτικές υπηρεσίες, τις τηλεπικοινωνίες και τις καμπάνιες άμεσου marketing στη λιανική πώληση. Αυτό μπορεί να συμβαίνει επειδή για τη μοντελοποίηση απαιτείται μια μεγαλύτερη και συνεπώς πιο δαπανηρή ομάδα δοκιμής, δεδομένου ότι πρέπει να διαμορφωθούν τόσο το Control όσο και το Test γκρουπ. Εκτιμάται ότι χρειάζονται περισσότεροι από 100.000 πελάτες.

Τα Uplift μοντέλα δημιουργούν βελτίωση κυρίως με τη μείωση του μεγέθους της ομάδας που θα γίνει η επαφή και στην περίπτωση της απώλειας πελατών, μειώνοντας τον αριθμό εκείνων που χάνονται λόγω της εκστρατείας. Κάποια τμήματα marketing μπορεί να πιστεύουν πως η επαφή σε μικρότερες ομάδες είναι αρνητική. Εκτός των άλλων, με ένα μοντέλο Uplift μπορεί επίσης να αποκαλυφθεί το αν προηγούμενη στόχευση ήταν καλή ή όχι. Υπάρχουν αναφορές ότι τα μοντέλα μπορεί να χρειαστεί να ανανεώνονται συχνότερα, αλλά επιτυγχάνουν μεγάλες βελτιώσεις στην απόδοση της εκστρατείας.

Ένας ακόμα λόγος που επιβραδύνει την υιοθέτηση του είναι ότι ακόμα δεν έχει αξιοποιηθεί πλήρως από τα υπάρχοντα εργαλεία. Υπάρχει ένα πακέτο στην R ενώ και τα υπόλοιπα εργαλεία μπορούν να καλύψουν τις ανάγκες της μοντελοποίησης.

5.3 Το μέλλον

Βρισκόμαστε σε μια συναρπαστική εποχή αφού ό,τι συνέβη με καμπάνιες ηλεκτρονικού ταχυδρομείου, όπου όλο και περισσότερες εταιρείες χρησιμοποιούν ομάδες ελέγχου για τη μέτρηση της πραγματικής αυξητικής τάσης, θα συνεχιστεί αναμφίβολα στην online διαφήμιση.

Θα αρχίσουμε να βλέπουμε συστηματικά ομάδες ελέγχου στις διαφημίσεις. Για κάθε αλληλεπίδραση στο ταξίδι του πελάτη, ο έμπορος θα είναι σε θέση να εκτιμήσει την πραγματική επίδραση της κάθε διαφήμισης, δηλαδή τη διαφορά μεταξύ της ομάδας που εκτέθηκε στη διαφήμιση και την ομάδα που δεν εκτέθηκε (ή εκτέθηκε σε διαφήμιση ενός ανταγωνιστή). Αυτό είναι πολύ σημαντικό, καθώς θα παρέχει μια άποψη σχετικά με τις συνέπειες. Επιπλέον είναι μια ακριβής και επιστημονική μέθοδος, σε αντίθεση με μια άκρως υποκειμενική μεθοδολογία που χρησιμοποιεί αυθαίρετα ορισμένες παραμέτρους.

Η μέτρηση του Uplift θα αποτελέσει κρίσιμο παράγοντα. Θα αναγκάσει τους

παρόχους διαφημίσεων να αλλάξουν τη νοοτροπία τους από το να είναι στο ταξίδι του πελάτη, στο να διαφοροποιήσουν το ταξίδι αυτό. Είναι σίγουρο ότι θα κάνουν τις διαφημίσεις πιο σχετικές ενώ θα παρέχουν πιο στοχευμένο περιεχόμενο.

Βιβλιογραφία

- Cai, T.; Tian, L.; Wong, P. H.; and Wei, L. J. (2009); Analysis of Randomized Comparative Clinical Trial Data for Personalized Treatment Selections, Harvard University Biostatistics Working Paper Series, Paper 97
- Couban, Stephen, et al. "A randomized multicenter comparison of bone marrow and peripheral blood in recipients of matched sibling allogeneic transplants for myeloid malignancies." *Blood* 100.5 (2002): 1525-1531.
- Gartner (2015) Hype Cycle for Advanced Analytics and Data Science.
- Grundhoefer, M.D. and Bank, U.S., (2009). Raising the bar in cross-sell marketing with uplift modeling. In Predictive analytics world conference.
- Guelman, L., Guillén, M. and Pérez-Marín, A.M., (2012). Random forests for uplift modeling: an insurance customer retention case. In Modeling and Simulation in Engineering, Economics and Management (pp. 123-133). Springer Berlin Heidelberg.
- Guelman, L., Guillén, M. and Pérez-Marín, A.M., (2015). Uplift random forests. *Cybernetics and Systems*, 46(3-4), pp.230-248.
- Hansotia, B., & Rukstales, B. (2002). Incremental value modeling. *Journal of Interactive Marketing*, 16(3), 35.
- Hillstrom K. (2008). MineThatData Email Analytics And Data Mining Challenge: An Approach Using Uplift Modelling. Available at <http://blog.minethatdata.com/2008/03/minethatdata-e-mail-analytics-and-data.html>
- Jaskowski, M. and Jaroszewicz, S. (2012) Uplift Modeling for Clinical Trial Data. In ICML 2012 Workshop on Machine Learning for Clinical Data Analysis, Edinburgh, Scotland.
- Lo, V. (2002). "The True Lift Model: A Novel Data Mining Approach to Response Modeling in Database Marketing." *ACM SIGKDD Explorations Newsletter* 4:78–86.
- Nie, Norman H., Dale H. Bent, and C. Hadlai Hull. *SPSS: Statistical package for the social sciences*. No. HA29 S6. New York: McGraw-Hill, 1970.
- Oana, S.E. and Iulian, P., (2002). Improving Customer Churn Models as one of Customer Relationship Management Business Solutions for the Telecommunication Industry. *Economic Sciences Series*, University of Constantza, Faculty of Economic Sciences, 4(1), pp.1156-1160.

- Pintilie, Melania. *Competing risks: a practical perspective*. Vol. 58. John Wiley & Sons, 2006.
- Radcliffe N. J. and Surry, P. D. (1999). Differential response analysis: Modeling true response by isolating the effect of a single action. In *Proceedings of Credit Scoring and Credit Control VI*. Credit Research Centre, University of Edinburgh Management School.
- Radcliffe, N. J. (2007). *Generating Incremental Sales: Maximizing the Incremental Impact of Cross-Selling, Up-Selling and Deep-Selling Through Uplift Modelling*. Stochastic Solutions Limited .
- Radcliffe, N. J. (2007b); Using Control Groups to Target on Predicted Lift: Building and Assessing Uplift Models, *Direct Marketing Analytics Journal*, Direct Marketing Association
- Radcliffe, N.J. and Simpson, R., (2008). Identifying who can be saved and who will be driven away by retention activity. *Journal of Telecommunications Management*, 1(2).
- Radcliffe, N.J. and Surry, P.D., (2011). Real-world uplift modelling with significance-based uplift trees. White Paper TR-2011-1, Stochastic Solutions.
- Rzepakowski, P., Jaroszewicz, S., (2012). Decision trees for uplift modeling with single and multiple treatments. *Knowledge and Information Systems*, 32(2), pp.303-327.
- Rzepakowski, P., Jaroszewicz, S., (2012b). Uplift modeling in direct marketing. *Journal of Telecommunications and Information Technology*, pp.43-50.
- Rzepakowski, P., Jaroszewicz, S. (2010). "Decision trees for uplift modeling". In *Proceedings of the 10th IEEE International Conference on Data Mining (ICDM'10)*. Sydney, Australia: 441–450.
- Sisifos (2016). Cost/benefit evaluation of Uplift Modeling with an example in R. Blog post available at <http://sisifospage.tech/2016-04-01-uplift-evaluation.html>
- Sołtys, M., Jaroszewicz, S. and Rzepakowski, P., (2015). Ensemble methods for uplift modeling. *Data mining and knowledge discovery*, 29(6), pp.1531-1559.
- Vittal S., Spivey Overby C. and Bowen, E. (2008). *Optimizing Customer Retention Programs*. Available online at http://www.pbinsight.com/assets_microsite/resources/files/telenor-cs.pdf

Παράρτημα

Ο παραδοσιακός ταξινομητής προσπαθεί να εκτιμήσει την πιθανότητα μετατροπής (y ως απόκριση) χρησιμοποιώντας τα χαρακτηριστικά του τύπου. Για όλους τους πελάτες που έχουν πραγματοποιήσει μετατροπή, ανεξάρτητα από το αν στοχεύθηκαν ή όχι, θα πρέπει $y == 1$. Αυτό είναι ένα αρκετά καλό σημάδι για την ανάπτυξη του μοντέλου.

Αντιθέτως, ο ταξινομητής Uplift θα προσπαθήσει να εκτιμήσει την οριακή πιθανότητα μετατροπής, χρησιμοποιώντας το z ως απάντηση. Το z παίρνει την τιμή 1 για τους πελάτες που στοχεύθηκαν και έχουν μετατρέψει, καθώς επίσης και για τους πελάτες που δε στοχεύθηκαν, άρα δε μετέτρεψαν.

Ένας τύπος με αλληλεπιδράσεις είναι ήδη πολύ καλύτερος για την εφαρμογή του μοντέλου και χρησιμοποιήθηκε για την αξιολόγηση.

```
url =  
"http://www.minethatdata.com/Kevin_Hillstrom_MineThatData_E-MailAnalytics_DataMiningChallenge_2008.03.20.csv"  
hc = read.csv(file=url)  
  
hc$treat <- ifelse(as.character(hc$segment) != "No E-Mail",  
TRUE, FALSE)  
hc$mens <- as.factor(hc$mens)  
hc$womens <- as.factor(hc$womens)  
hc$newbie <- as.factor(hc$newbie)  
  
require(uplift)  
?rvtu  
  
hc_rvtu <-  
rvtu(visit~recency+history_segment+history+mens+womens+zip_code+newbie+channel+trt(as.numeric(treat)),  
      data=hc[hc$segment != "Mens E-Mail",],  
      method="none")  
names(hc_rvtu)
```

```

explore(y~recency+history_segment+history+mens+omens+zip_code+
newbie+channel+trt(ct),
      data=hc_rvtu)
# targeted
count(hc_rvtu[hc_rvtu$ct == 1,], "y")$freq / sum(hc_rvtu$ct
== 1)
# control
count(hc_rvtu[hc_rvtu$ct == 0,], "y")$freq / sum(hc_rvtu$ct
== 0)

par(mfrow=c(2,3))
boxplot(recency~visit, data=hc[hc$treat,],
      ylab="recency", xlab="visit")
boxplot(recency~conversion, data=hc[hc$treat,],
      ylab="recency", xlab="conversion")
boxplot(split(hc$recency[hc$spend != 0 & hc$treat],
      cut(hc$spend[hc$spend != 0 & hc$treat], 3)),
      ylab="recency", xlab="spend for converted")
mtext("recency target", side=3, line=-3, outer=TRUE, cex=2,
font=2)
boxplot(recency~visit, data=hc[! hc$treat,],
      ylab="recency", xlab="visit")
boxplot(recency~conversion, data=hc[hc$treat,],
      ylab="recency", xlab="conversion")
boxplot(split(hc$recency[hc$spend != 0 & ! hc$treat],
      cut(hc$spend[hc$spend != 0 & ! hc$treat], 3)),
      ylab="recency", xlab="spend for converted")
mtext("recency control", side=3, line=-39, outer=TRUE, cex=2,
font=2)

pairs(~recency+history_segment+history,
      data=hc_rvtu, col=hc_rvtu$y+1)

logit.formula.interactions <-
as.formula(paste("~history_segment*mens+history_segment*women
s",
"history_segment*newbie",
"zip_code*mens+zip_code*omens+zip_code*newbie",

```

```

"channel*mens+channel*womens+channel*newbie",

"channel*history_segment",

                                sep="+"))

require(glmnet)
logit.x.interactions <-
model.matrix(logit.formula.interactions, data=hc_all_rvtu)
logit.z <- hc_all_rvtu$z
logit.y <- hc_all_rvtu$y

# traditional classifier, y as response
logit.cv.lasso.y.interactions <-
cv.glmnet(logit.x.interactions, logit.y, alpha=1,
family="binomial")
plot(logit.cv.lasso.y.interactions)

# uplift classifier, z as response
logit.cv.lasso.z.interactions <-
cv.glmnet(logit.x.interactions, logit.z, alpha=1,
family="binomial")
plot(logit.cv.lasso.z.interactions)

coef(logit.cv.lasso.z.interactions)[which(coef(logit.cv.lasso
.z.interactions) != 0),]

coef(logit.cv.lasso.z.interactions,

s=logit.cv.lasso.z.interactions$lambda.min)[which(coef(logit.
cv.lasso.z.interactions,

s=logit.cv.lasso.z.interactions$lambda.min) != 0),]

require(ROCR)
preds.y.interactions.lse <-
predict(logit.cv.lasso.y.interactions, logit.x.interactions,

s=logit.cv.lasso.y.interactions$lambda.lse, type="response")
pred.y <- prediction(preds.y.interactions.lse, hc_rvtu$y)
auc.y <- performance(pred.y, "auc")

```

```

as.numeric(auc.y@y.values)

preds.z.interactions.lse                                     <-
predict(logit.cv.lasso.z.interactions, logit.x.interactions,

s=logit.cv.lasso.z.interactions$lambda.lse, type="response")
pred.z <- prediction(preds.z.interactions.lse, hc_rvtu$z)
auc.z <- performance(pred.z, "auc")
as.numeric(auc.z@y.values)

qini_from_data(preds.z.interactions.lse,
               hc_rvtu,
               plotit=TRUE,
               x_axis_ratio=TRUE)

# 1. compare cumulative responses just taking into account
#      classifications (not much sense for the uplift)
par(mfrow=c(2,1))
cumulative_response(preds.y.interactions.lse,
                   hc_all_rvtu,
                   "y",
                   x_axis_ratio=TRUE)

cumulative_response(preds.z.interactions.lse,
                   hc_all_rvtu,
                   plotit=TRUE,
                   x_axis_ratio=TRUE)

# 2. compare cumulative penalized as in qini (of course
#      traditional classifier is worse)
par(mfrow=c(2,1))
cum_penalized_curve(preds.y.interactions.lse,
                   hc_all_rvtu,
                   "y",
                   "z",
                   x_axis_ratio=TRUE)

cum_penalized_curve(preds.z.interactions.lse,
                   hc_all_rvtu,
                   "y",

```



```
"ct",  
x_axis_ratio=TRUE)
```