

XII

CONGRESSO NAZIONALE degli ATTUARI

Cross-Selling

Machine Learning in campo assicurativo

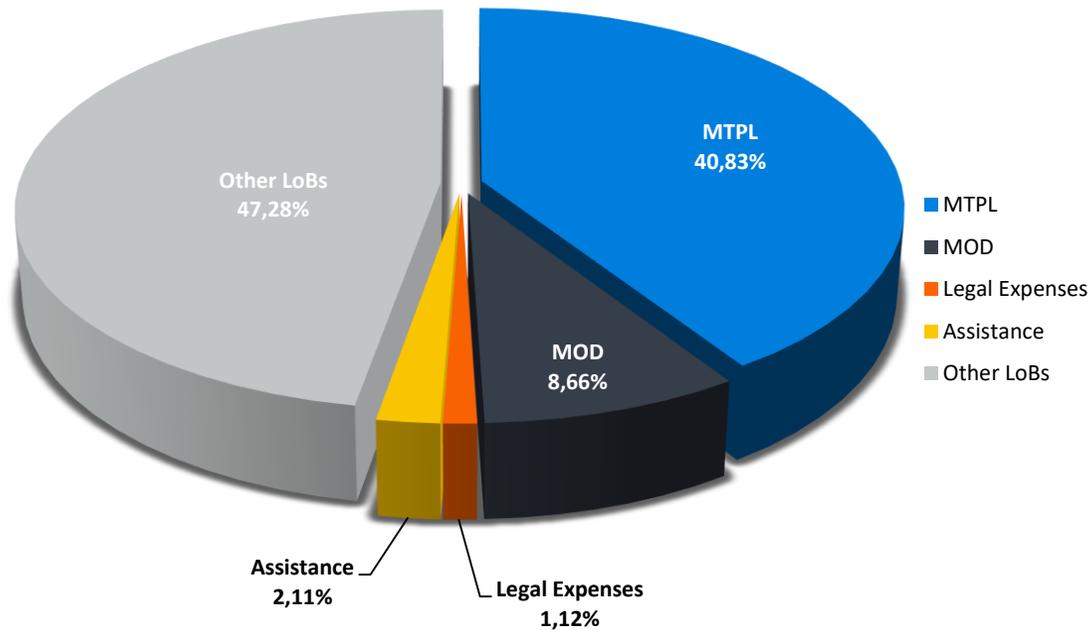
Nicola Biscaglia – Alessandro Zanetti

23 novembre 2018



Mercato assicurativo italiano – *Non Life business*

% Premi contabilizzati (2017)

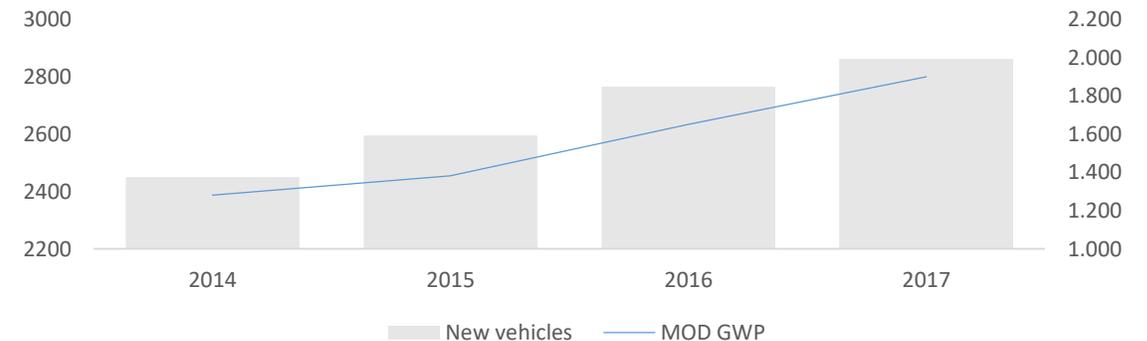


Fonte: ANIA Report 2017

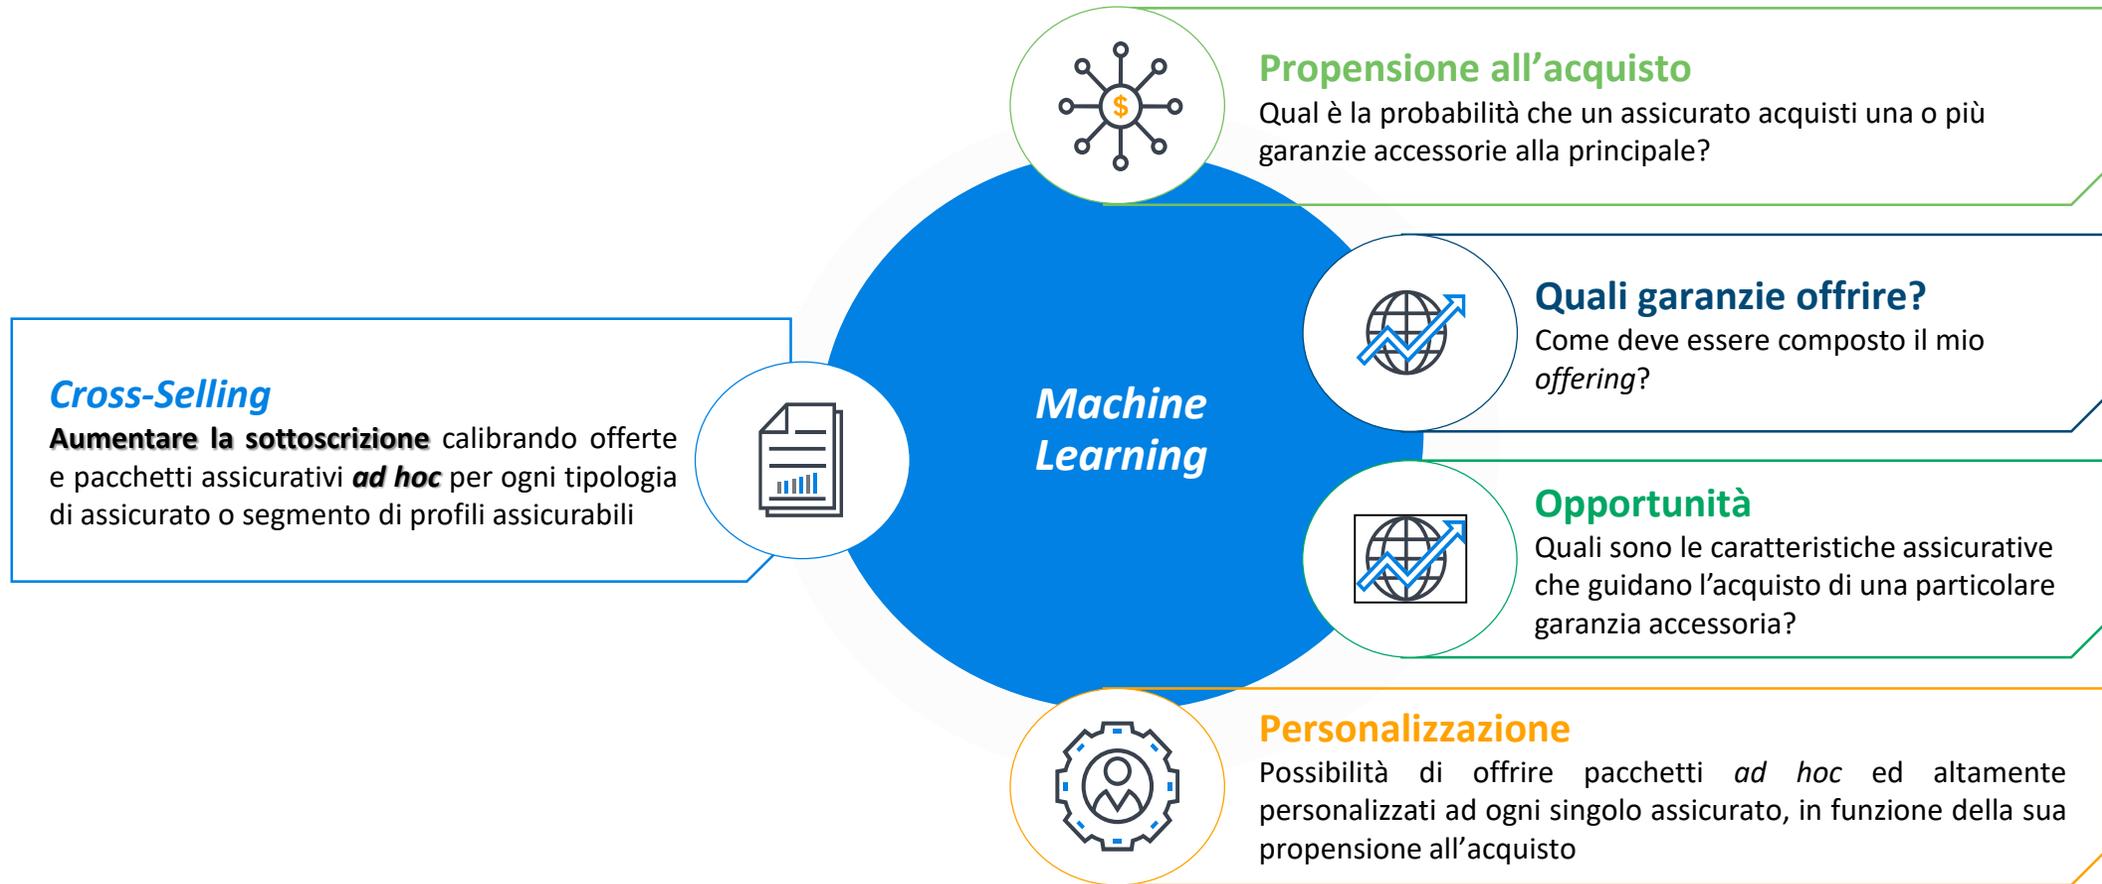
MTPL	2015	2016	2017	MOD	2015	2016	2017
Loss Ratio	72,1%	76,1%	75,9%	Loss Ratio	58,2%	57,4%	60,6%
Expenses Ratio	21,5%	21,4%	21,2%	Expenses Ratio	29,8%	30,5%	30,7%
Combined Ratio	93,6%	97,6%	97,1%	Combined Ratio	88,0%	87,9%	91,3%

MOD registra sempre un livello di profittabilità più alta del MTPL

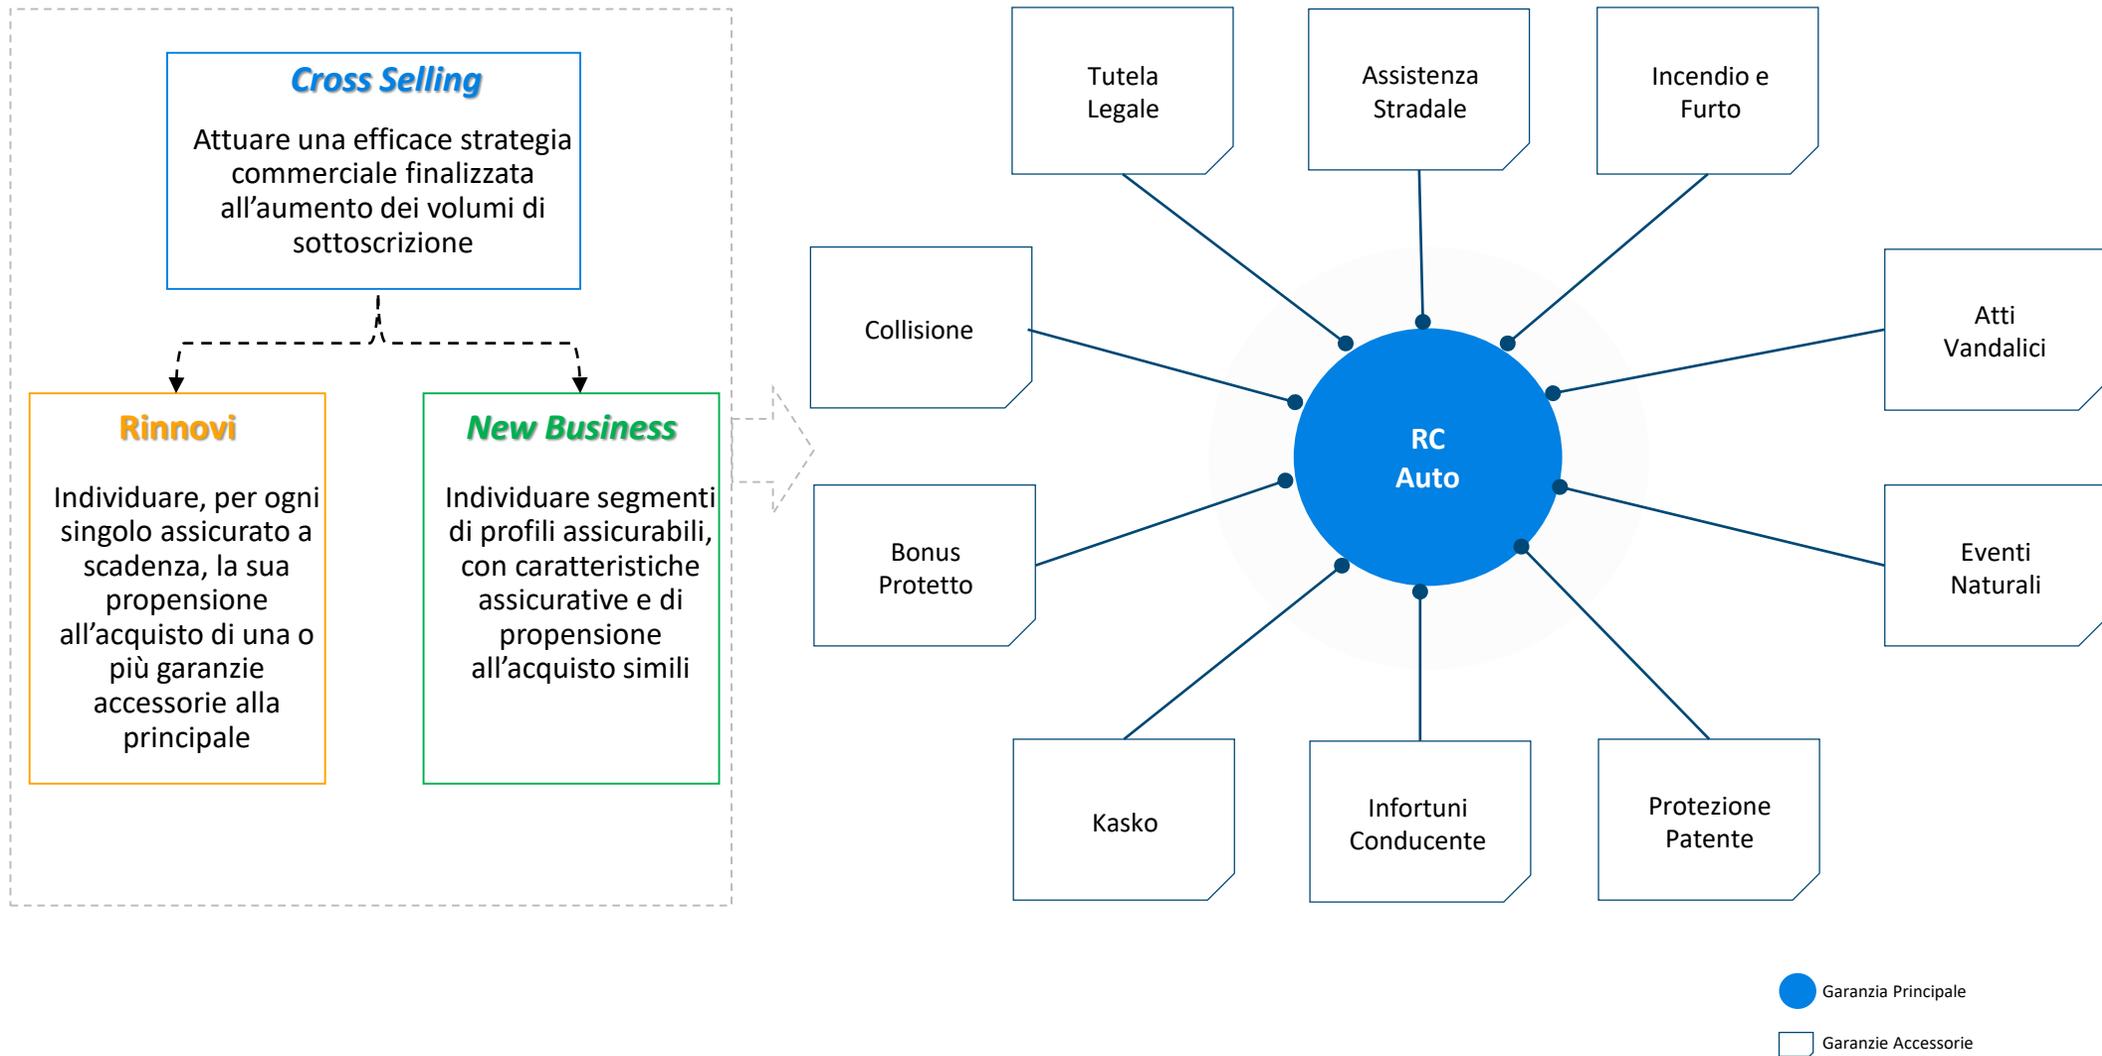
I volume del MOD sono cresciuti negli ultimi anni, anche grazie alla forte connessione che queste coperture hanno con le nuove immatricolazioni, che risultano anch'esse in crescita



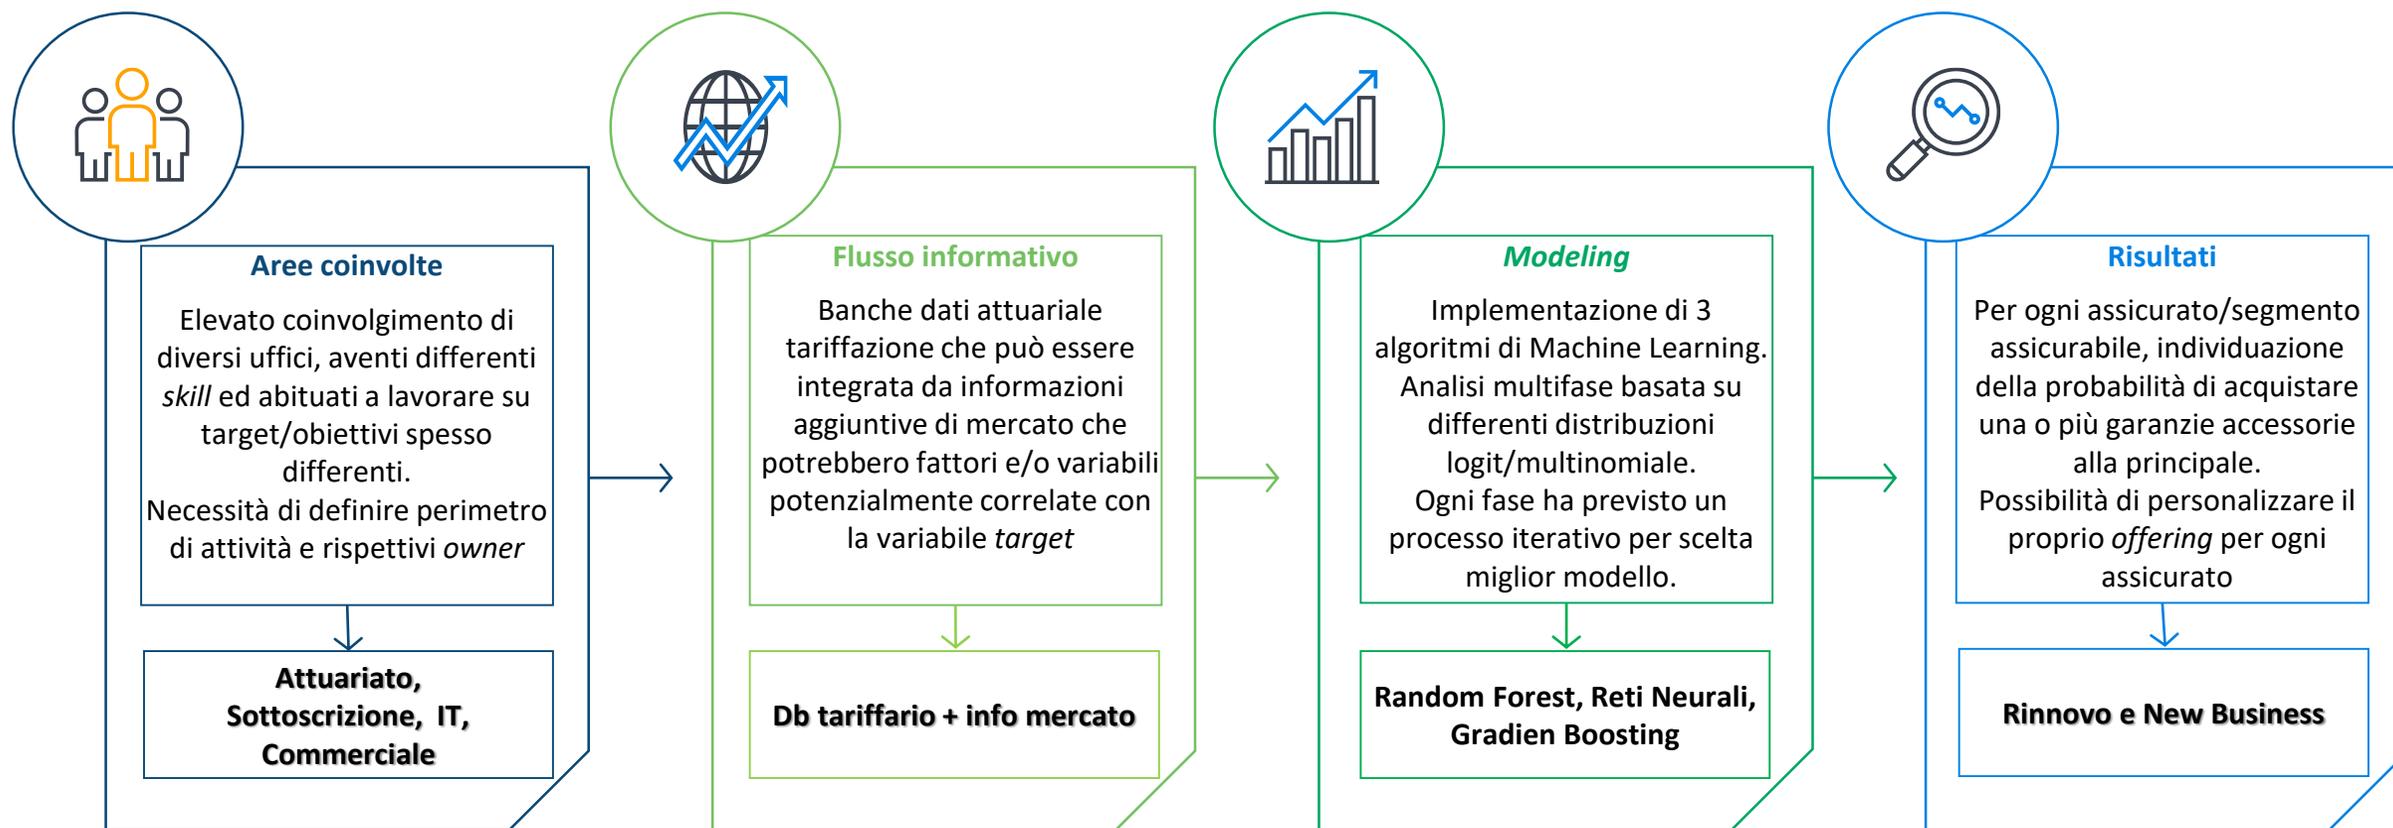
Perché fare *Cross-Selling*? (1)



Perché fare *Cross-Selling*? (2)

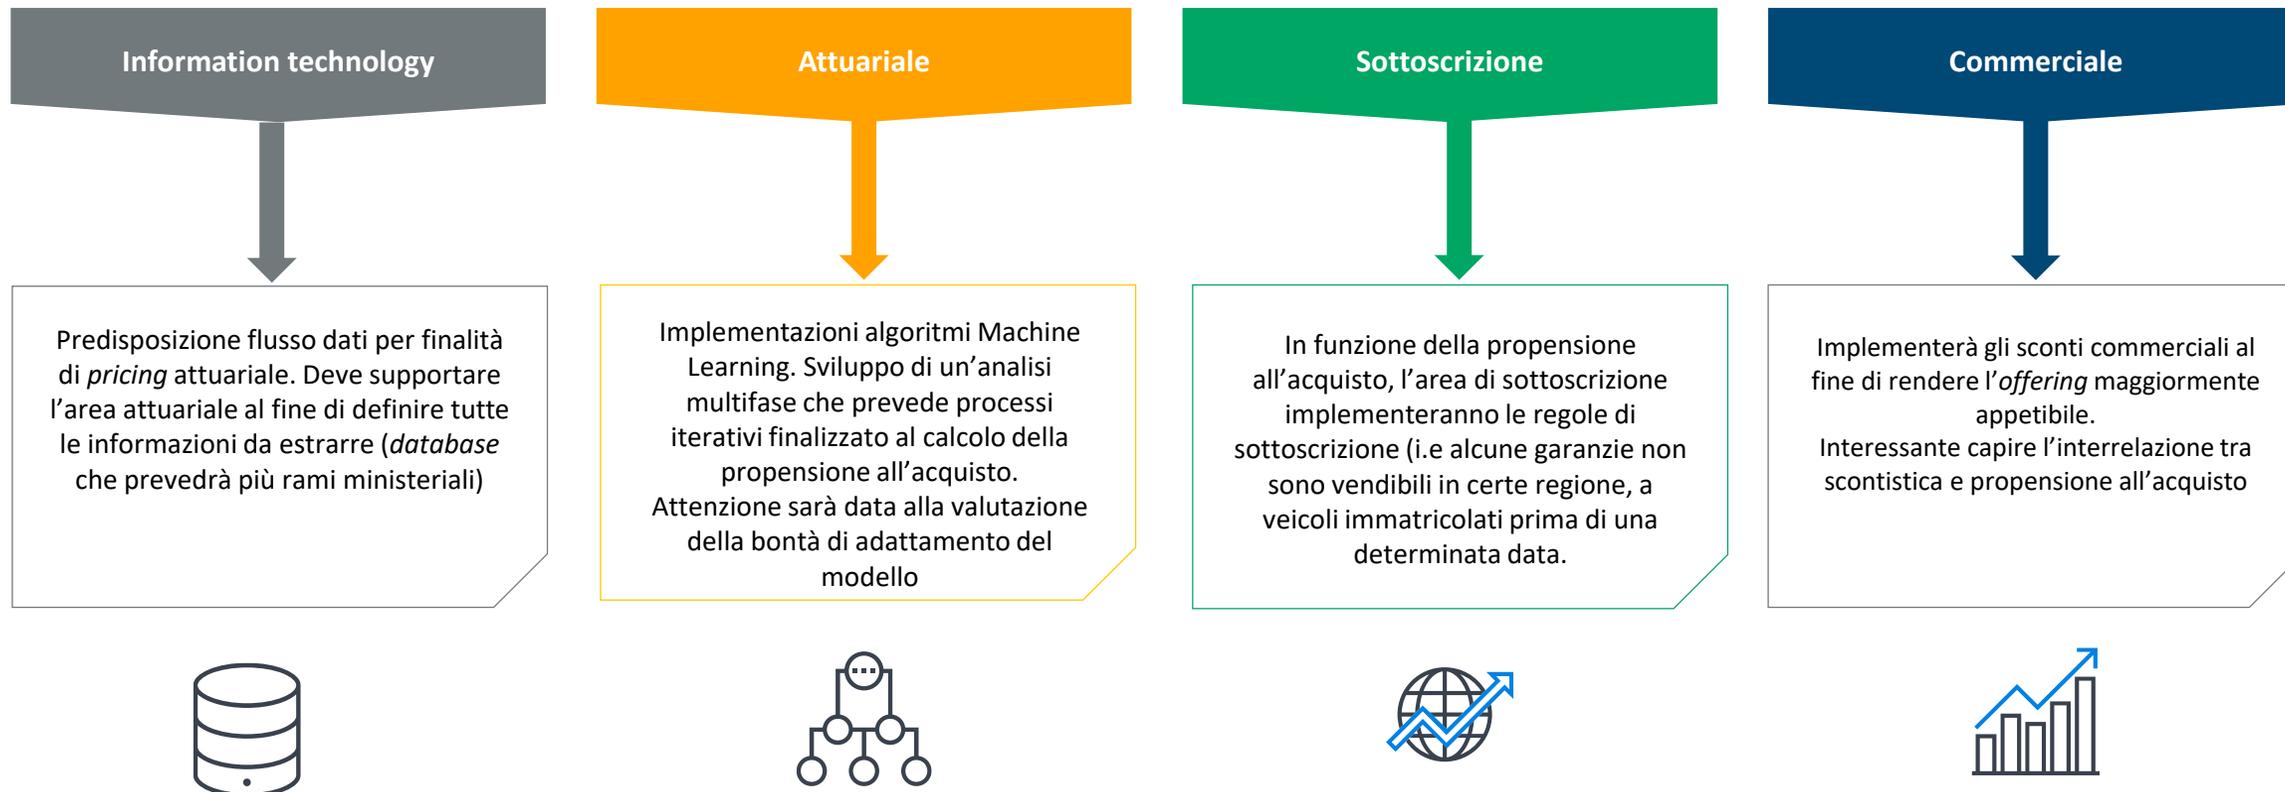


Cross-Selling: Workflow



Cross-Selling: Aree coinvolte

Compagnia - uffici



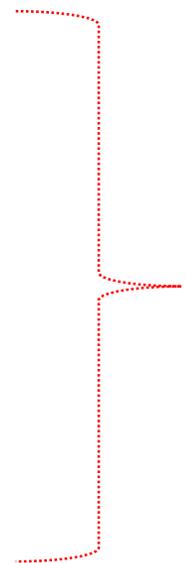
Cross-Selling: Flusso informativo (1)

Come gestire il **flusso informativo** per gli algoritmi di **Machine Learning**?



Apprendono direttamente dai dati

Ma gli algoritmi di Machine Learning come «**imparano dai dati**»?



Apprendimento supervisionato. Analizza contemporaneamente la relazione tra *input* e la variabile *target* → Identifica una regola

Apprendimento non supervisionato. Viene fornito solamente gli *input* → Risale a modelli e schemi nascosti identificando negli *input* una struttura logica che li classifica

Apprendimento semi supervisionato. Flusso dati ibrido, consistente di dati incompleti (alcuni hanno variabile *target*, altri no) → Identifica regole/schemi

Apprendimento per rinforzo. Ambiente dinamico (presenza di *input*) e mira a raggiungere un obiettivo → Ricompensa se la prestazione è buona ed una punizione se non lo è

Come funzionano gli algoritmi di **apprendimento supervisionato**?



Tecniche di apprendimento finalizzate ad individuare una **insieme di regole o di compiti da risolvere** attraverso una serie di esempi concreti (costituiti da *input* e variabili *target*)

Quale **flusso informativo** per algoritmi **apprendimento supervisionato**?



Prevede un flusso informativo costituito da variabili **indipendenti/esplicative** e dalla variabile **dipendente/risposta**



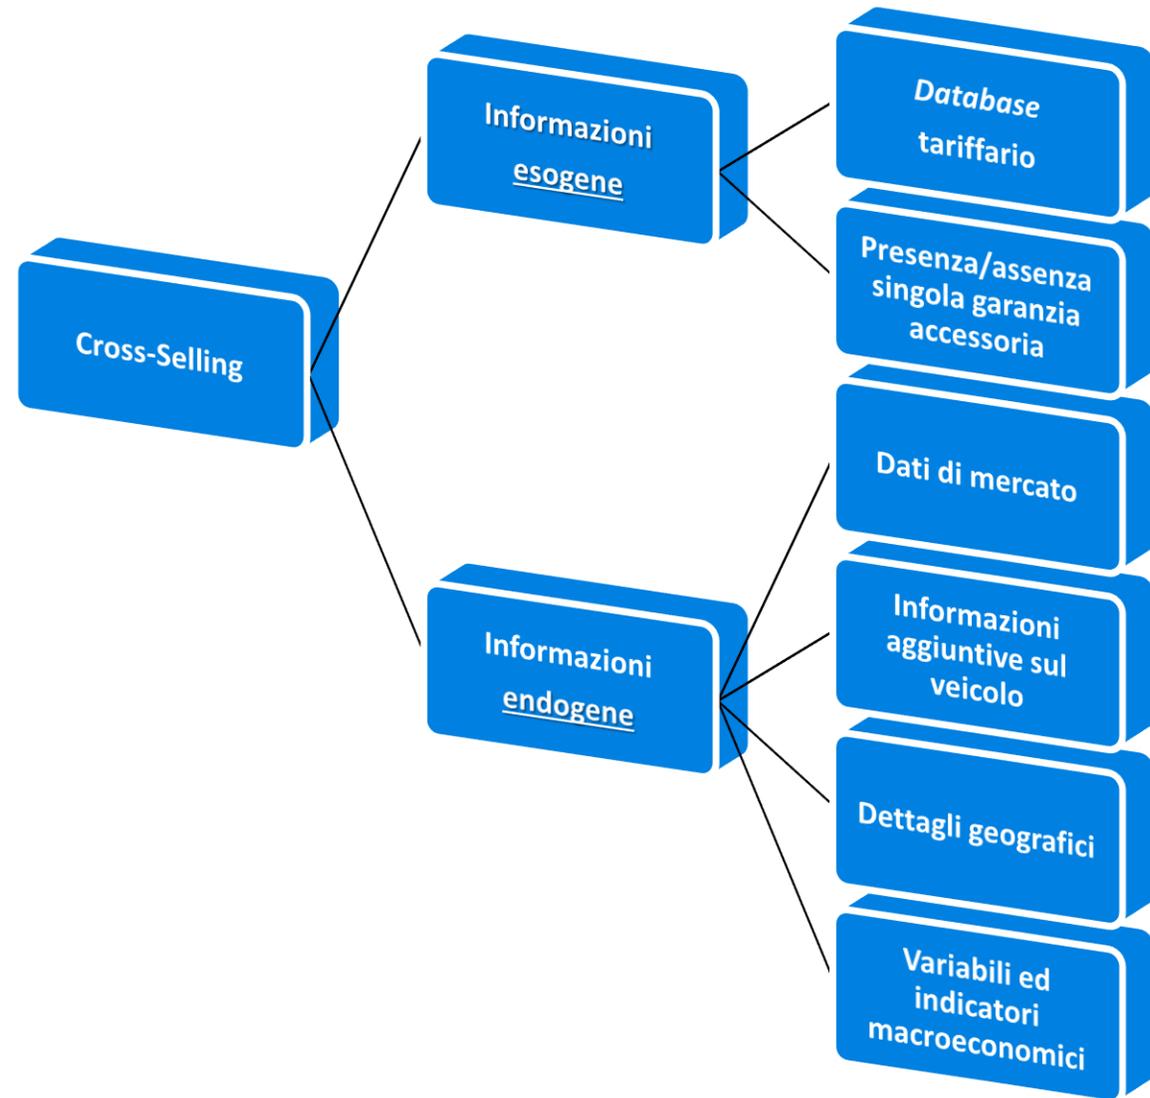
Cross-Selling: Flusso informativo (2)

```
> # RANDOM FOREST
> set.seed(42)
> # IMPUTE VALUES for the NA
> data.imputed<-rfImpute(hd~., data=data, iter=6) #hd=heart disease #iter=iteration #OOB=Out-Of-Bag error rate
ntree   OOB    1    2
300: 17.49% 12.80% 23.02%
ntree   OOB    1    2
300: 16.83% 14.02% 20.14%
ntree   OOB    1    2
300: 17.82% 13.41% 23.02%
ntree   OOB    1    2
300: 17.49% 14.02% 21.58%
ntree   OOB    1    2
300: 17.16% 12.80% 22.30%
ntree   OOB    1    2
300: 18.15% 14.63% 22.30%
> summary(data.imputed)
      hd          age          sex          cp          trestbps          chol          fbs          restecg
Healthy :164  Min.   :29.00  F: 97  1: 23  Min.   : 94.0  Min.  :126.0  0:258  0:151
Unhealthy:139 1st Qu.:48.00  M:206 2: 50 1st Qu.:120.0 1st Qu.:211.0  1: 45  1:  4
              Median :56.00          3: 86 Median :130.0 Median :241.0
              Mean   :54.44          4:144 Mean  :131.7 Mean  :246.7
              3rd Qu.:61.00          3rd Qu.:140.0 3rd Qu.:275.0
              Max.   :77.00          Max.   :200.0 Max.   :564.0

      thalach          exang          oldpeak          slope          ca          thal
Min.   : 71.0  0:204  Min.   :0.00  1:142  2:179  2:168
1st Qu.:133.5  1: 99  1st Qu.:0.00  2:140  3: 65  3: 18
Median :153.0          Median :0.80  3: 21  4: 38  4:117
Mean   :149.6          Mean  :1.04          5: 21
3rd Qu.:166.0          3rd Qu.:1.60
Max.   :202.0          Max.   :6.20
>
> model<-randomForest(hd~., data=data.imputed, proximity=TRUE)
> model

Call:
randomForest(formula = hd ~ ., data = data.imputed, proximity = TRUE)
Type of random forest: classification
Number of trees: 500
No. of variables tried at each split: 3

OOB estimate of error rate: 16.83%
Confusion matrix:
      Healthy Unhealthy class.error
Healthy   142      22  0.1341463
Unhealthy   29     110  0.2086331
```



Cross-Selling: Modeling



Random Forest

Distribution free e basato su alberi di classificazione (1/0).

Il nostro processo iterativo ha testato circa 1.000 differenti RF, iterando **dimensione nodi finali**, **massimo numero di nodi finali** ed **il numero di variabili campionate** casualmente all'interno di ogni iterazione.

La scelta della RF migliore è stata basata sul livello di bontà di stima degli **Out of Bag**



Boosting

Distribuzione logit (Bernoulli)

Il nostro processo iterativo ha testato circa 1.000 differenti *gradient boosting*, iterando il **numero di alberi**, il **tasso di apprendimento**, la massima profondità di ciascun albero ed il **numero minimo di osservazioni** all'interno dei nodi finali

La scelta del GB migliore è stata basata sul livello di bontà della stima del **validation set**.

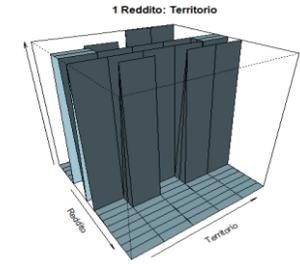
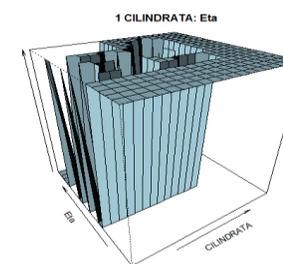
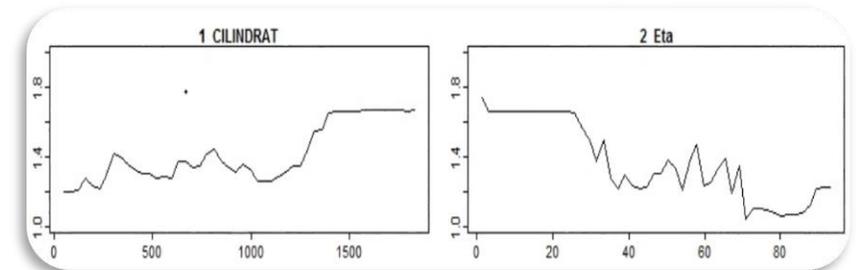
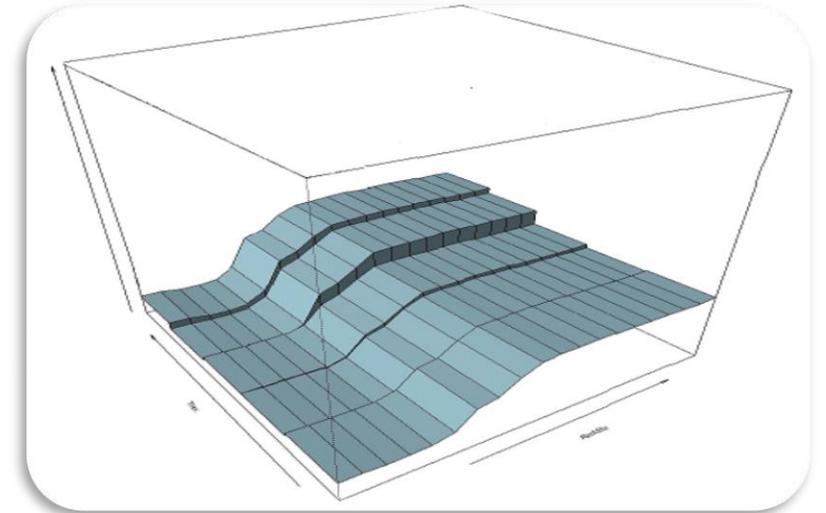


Reti neurali

Distribuzione multinomiale (multinomial log-linear modello)

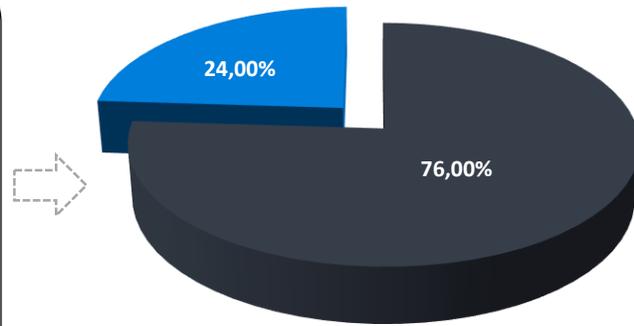
Il nostro processo iterativo ha testato circa 500 differenti reti neurali, iterando il numero di **cross validation** ed il numero di **interazioni**.

La scelta della NN migliore è stata basata sul livello di bontà di stima del **validation set**.

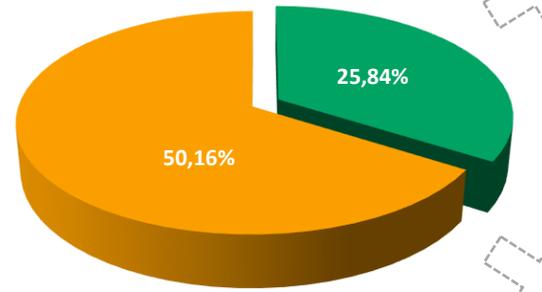


Cross-Selling: Risultati

Marca: Fiat
Modello: 500
Allestimento: Pop
Residenza: Milan
...
...
Anni assicurato: 4



■ Probabilità di acquistare **almeno una** garanzia accessoria
■ Probabilità di acquistare **solo** MTPL



■ Probabilità di acquistare **almeno una garanzia legata al** valore del veicolo
■ Probabilità di acquistare **solo garanzie non legate** al valore del veicolo

