



# Τεχνητή Νοημοσύνη και Μηχανική Μάθηση

---

Κωνσταντίνος Καραμανής

The University of Texas at Austin & Archimedes/Athena RC

[constantine@utexas.edu](mailto:constantine@utexas.edu)

<https://caramanis.github.io/>





Ας θυμηθούμε τα  
προηγούμενα...



## Πρόβλεψη Διαβήτη

Ο Διαβήτης είναι η 8η κυριότερη αιτία θανάτου στις ΗΠΑ. Ένα από τα βασικότερα προβλήματα είναι η σωστή διάγνωση, όσο και η πρόβλεψη, και η πρόληψη.

|   | Pregnancies | Glucose | BloodPressure | SkinThickness | Insulin | BMI  | DiabetesPedigreeFunction | Age | Outcome |
|---|-------------|---------|---------------|---------------|---------|------|--------------------------|-----|---------|
| 0 | 6           | 148     | 72            | 35            | 0       | 33.6 | 0.627                    | 50  | 1       |
| 1 | 1           | 85      | 66            | 29            | 0       | 26.6 | 0.351                    | 31  | 0       |
| 2 | 8           | 183     | 64            | 0             | 0       | 23.3 | 0.672                    | 32  | 1       |
| 3 | 1           | 89      | 66            | 23            | 94      | 28.1 | 0.167                    | 21  | 0       |
| 4 | 0           | 137     | 40            | 35            | 168     | 43.1 | 2.288                    | 33  | 1       |


## Πρόβλεψη Διαβήτη

Ο Διαβήτης είναι η 8η κυριότερη αιτία θανάτου στις ΗΠΑ. Ένα από τα βασικότερα προβλήματα είναι η σωστή διάγνωση, όσο και η πρόβλεψη, και η πρόληψη.


|   | Pregnancies | Glucose | BloodPressure | SkinThickness | Insulin | BMI  | DiabetesPedigreeFunction | Age | Outcome |
|---|-------------|---------|---------------|---------------|---------|------|--------------------------|-----|---------|
| 0 | 6           | 148     | 72            | 35            | 0       | 33.6 | 0.627                    | 50  | 1       |
| 1 | 1           | 85      | 66            | 29            | 0       | 26.6 | 0.351                    | 31  | 0       |
| 2 | 8           | 183     | 64            | 0             | 0       | 23.3 | 0.672                    | 32  | 1       |
| 3 | 1           | 89      | 66            | 23            | 94      | 28.1 | 0.167                    | 21  | 0       |
| 4 | 0           | 137     | 40            | 35            | 168     | 43.1 | 2.288                    | 33  | 1       |

$X_1$   $X_2$   $y$

# Πρώτος Αλγόριθμος: Δέντρο Απόφασης




Δέντρο απόφασης με βάθος = 1




Έχουμε 4 παραμέτρους:

- (1)  $i = 2$
- (2)  $\alpha = 45$
- (3)  $a = \text{μπλέ}$
- (4)  $b = \text{κόκκινο}$

# Πρώτος Αλγόριθμος: Δέντρο Απόφασης



Δέντρο απόφασης με βάθος = 2



Έχουμε 10 παραμέτρους:

(1-3)  $i = 2, j = 1, k = 1$

(4-6)  $\alpha_1 = 45, \alpha_2 = 100, \alpha_3 = 145,$

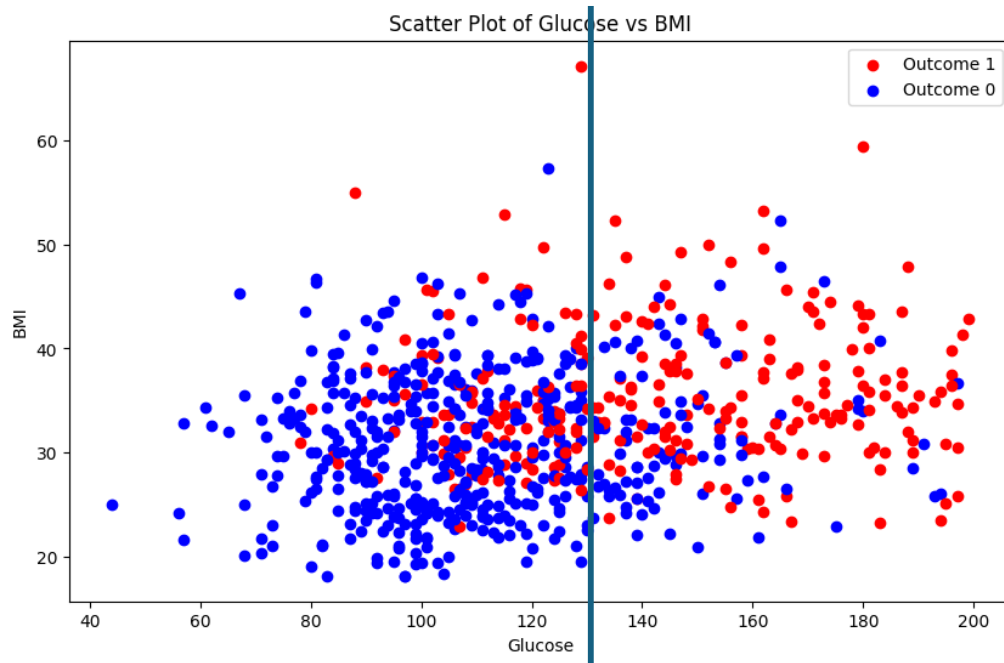
(7)  $a = \text{μπλέ}$

(8)  $b = \text{κόκκινο}$

(9)  $c = \text{μπλέ}$

(10)  $d = \text{κόκκινο}$

# Το «καλύτερο» δέντρο βάθους 1



Το καλύτερο δέντρο είναι αυτό που ελαχιστοποιεί τα λάθη!

# Εκπαίδευση Αλγορίθμου

---

1. Επιλέγουμε την οικογένεια αλγορίθμων: παράδειγμα – δέντρα απόφασης βάθους 3

---

2. Βρίσκουμε τις παραμέτρους που ελαχιστοποιούν τα λάθη στα δεδομένα μας



# Εκπαίδευση Αλγορίθμου

---

1. Επιλέγουμε την οικογένεια αλγορίθμων:  
παράδειγμα – δέντρα απόφασης βάθους 3

```
model = DecisionTreeClassifier(max_depth = 3)
```

---


2. Βρίσκουμε τις παραμέτρους που  
ελαχιστοποιούν τα λάθη στα δεδομένα μας

```
model.fit(X,y)
```

```
model.predict(x)
```

# Δεύτερο Παράδειγμα


---



Κέντρο  $c$  με ακτίνα  $p$ :  
εντός κύκλου μπλέ,  
εκτός κόκκινο

# Δεύτερο Παράδειγμα


---



Κέντρο  $c$  με ακτίνα  $p$ :  
εντός κύκλου μπλέ,  
εκτός κόκκινο

# Δεύτερο Παράδειγμα

---




Κέντρο  $c$  με ακτίνα  $\rho$ :  
εντός κύκλου μπλέ,  
εκτός κόκκινο

# Τρίτο Παράδειγμα

---


Δέντρο απόφασης με βάθος = 1




# Τρίτο Παράδειγμα

---

Δέντρο απόφασης με βάθος = 1




Δέντρο απόφασης με βάθος = 2




# Τρίτο Παράδειγμα

---

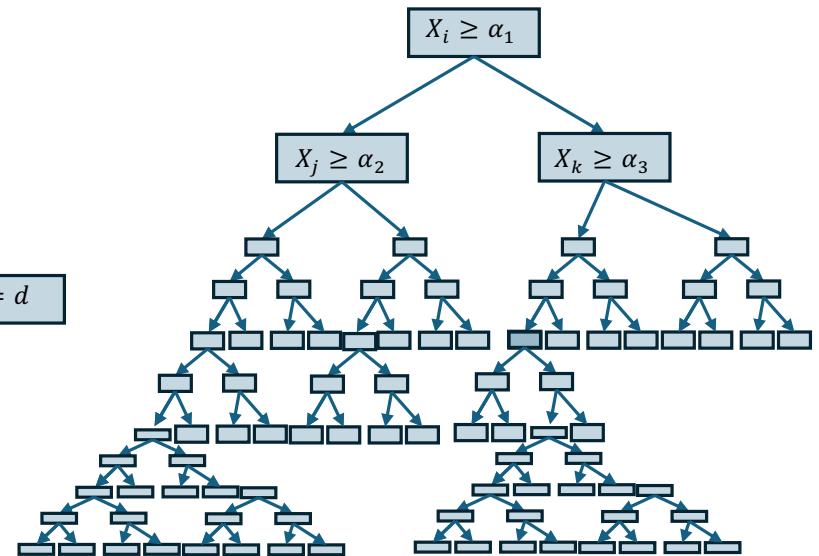
Δέντρο απόφασης με βάθος = 1



Δέντρο απόφασης με βάθος = 2




Δέντρο απόφασης με βάθος = 10+




# Τρίτο Παράδειγμα

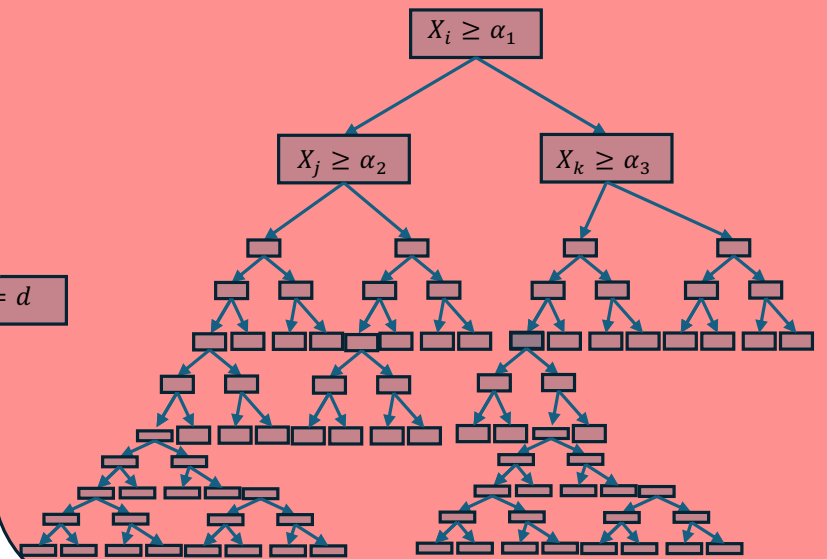
Δέντρο απόφασης με βάθος = 1



Δέντρο απόφασης με βάθος = 2

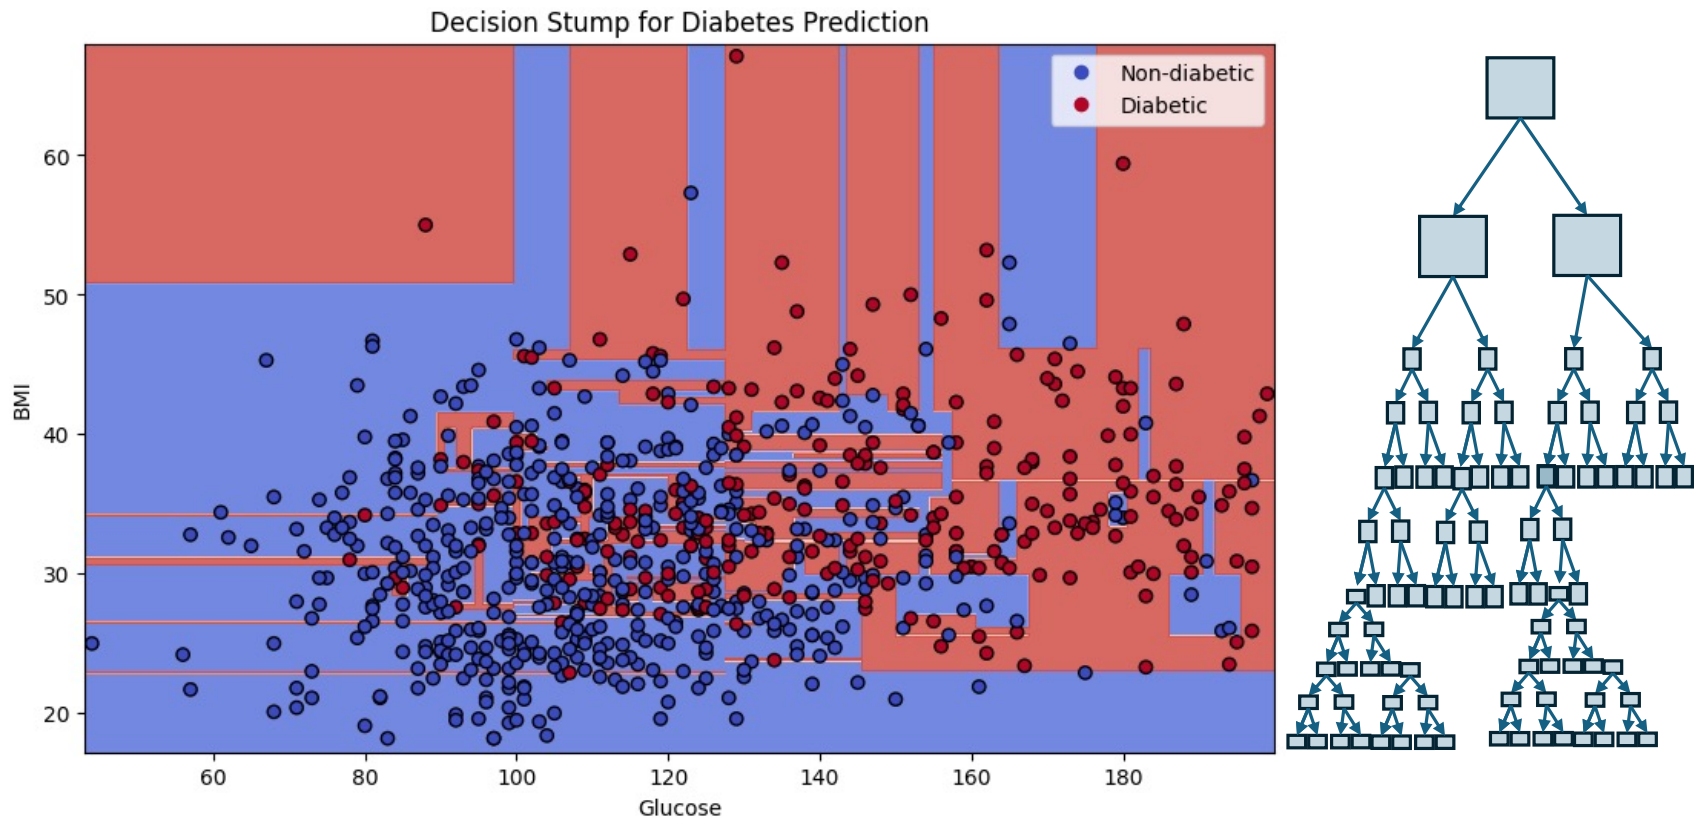


Δέντρο απόφασης με βάθος = 10+






# Τρίτο Παράδειγμα




# Τρίτο Παράδειγμα: Γιατί δεν μας αρέσει;

Decision Stump for Diabetes Prediction

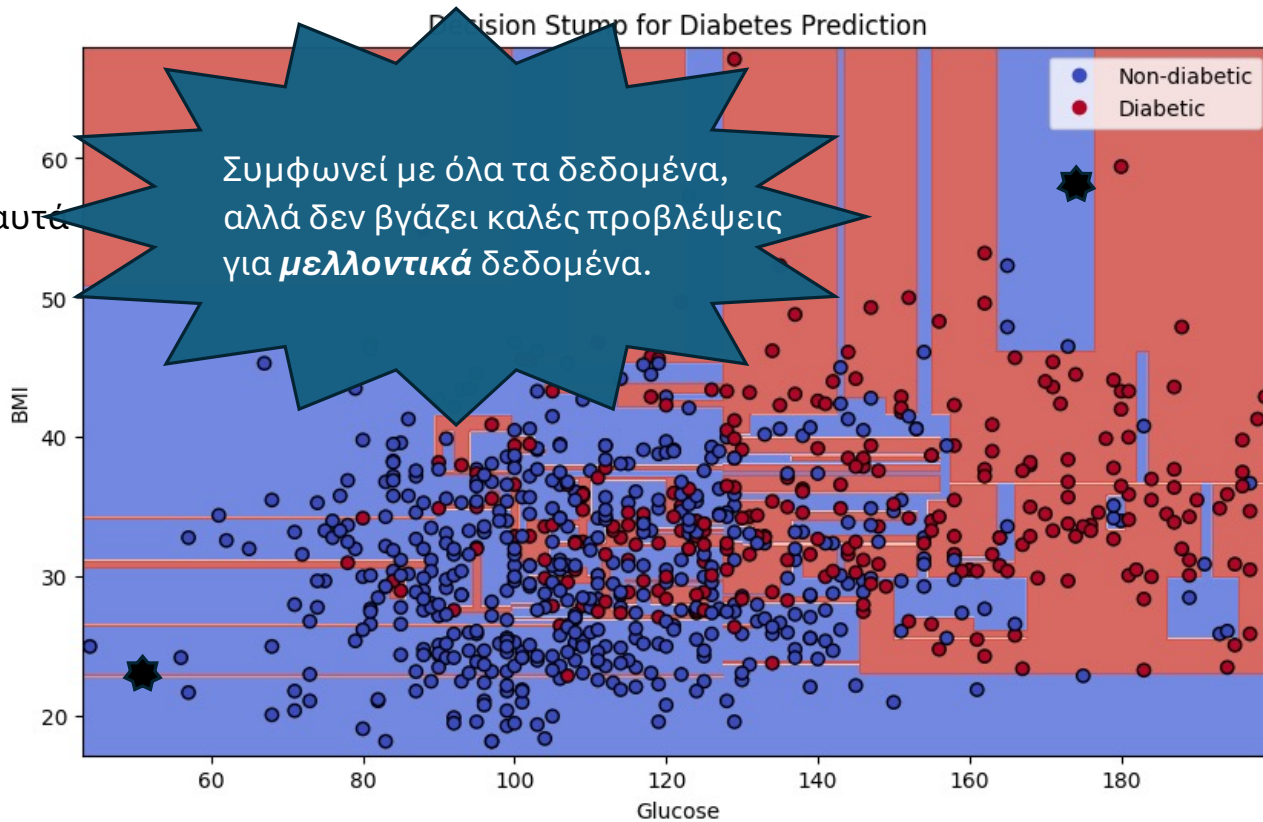


Τι λέει αυτός ο αλγόριθμος για αυτά τα δύο σημεία;

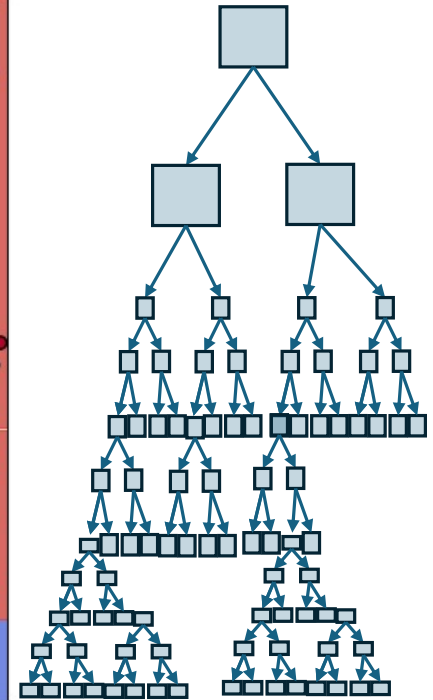


# Τρίτο Παράδειγμα: Γιατί δεν μας αρέσει;

Τι λέει αυτός ο αλγόριθμος για αυτά τα δύο σημεία;




Συμφωνεί με όλα τα δεδομένα, αλλά δεν βγάζει καλές προβλέψεις για **μελλοντικά** δεδομένα.

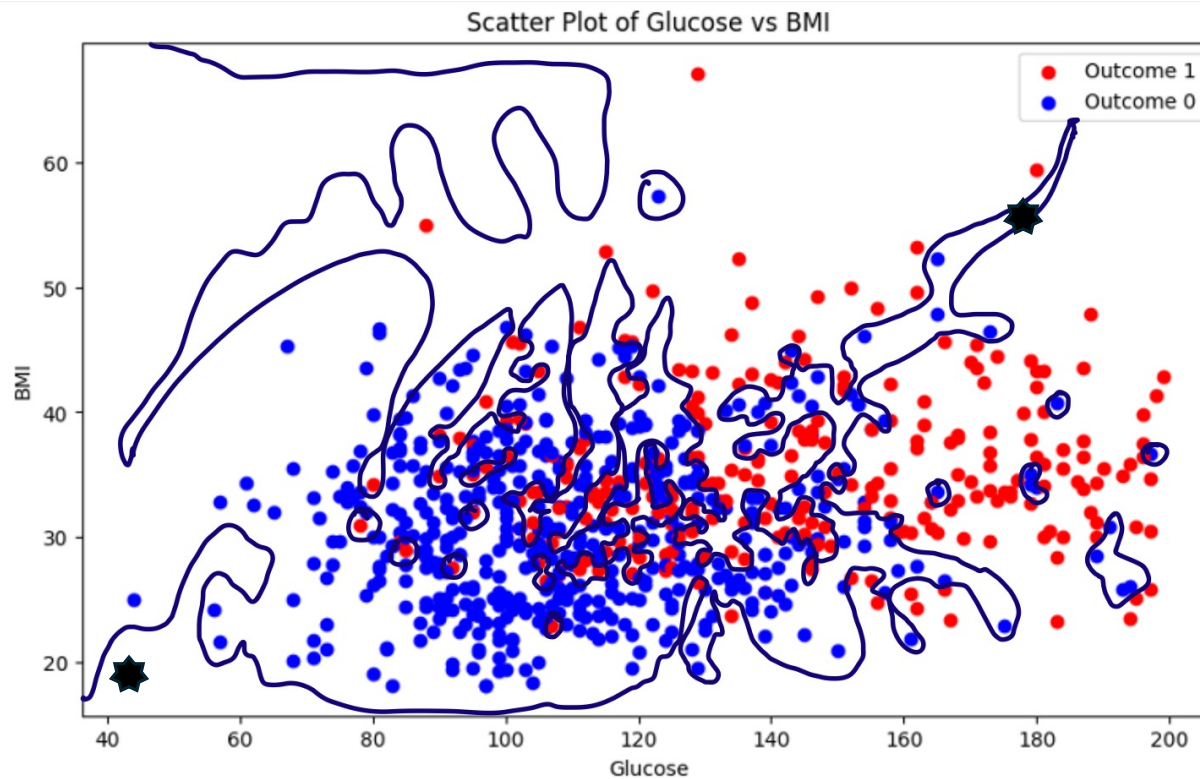


# Τέταρτο Παράδειγμα

---

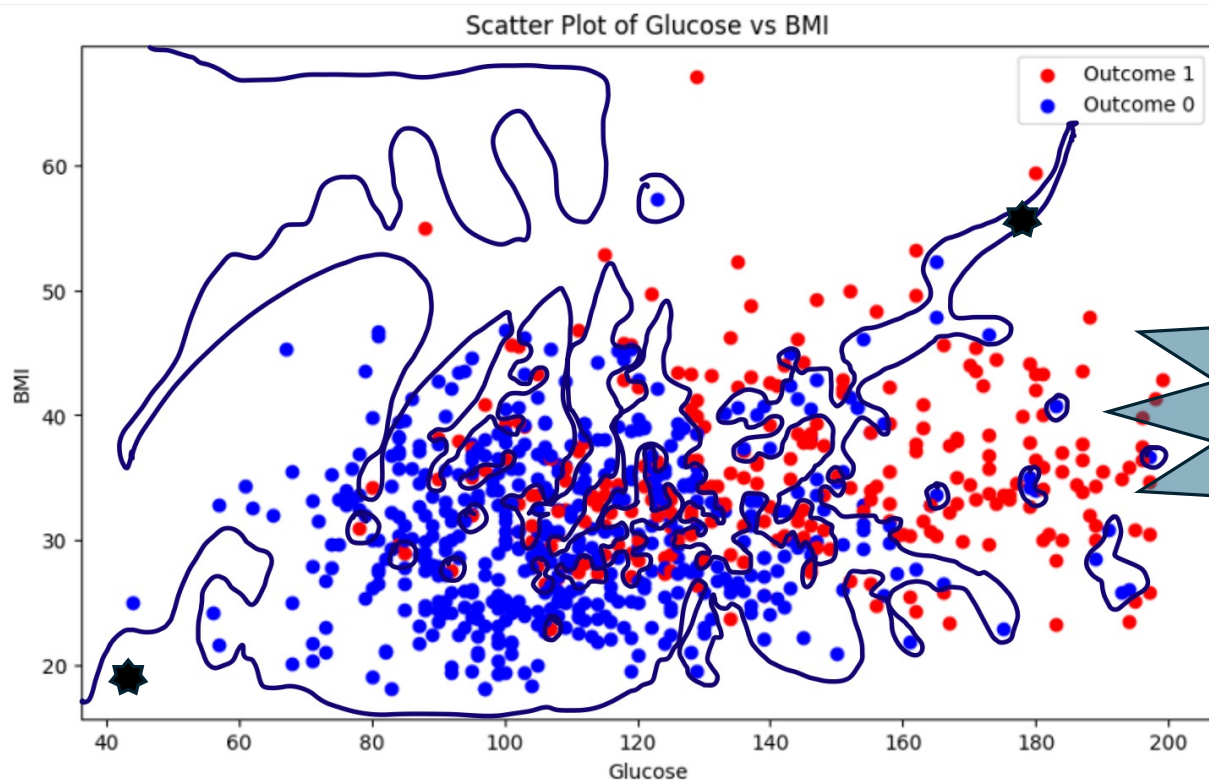


# Τέταρτο Παράδειγμα: Γιατί δεν μας αρέσει;



★ Τι λέει αυτός ο αλγόριθμος για αυτά τα δύο σημεία;

# Τέταρτο Παράδειγμα: Γιατί δεν μας αρέσει;



★ Τι λέει αυτός ο αλγόριθμος για αυτά τα δύο σημεία;

Συμφωνεί με όλα τα δεδομένα, αλλά δεν βγάζει καλές προβλέψεις για **μελλοντικά** δεδομένα.

## Υπερμοντελοποίηση - Overfitting

- Ένας αλγόριθμος **υπερμοντελοποιεί** εάν πετυχαίνει πολύ καλύτερη ακρίβεια στα δεδομένα με τα οποία εκπαιδεύτηκε (**training data**), συγκριτικά με την ακρίβεια που πετυχαίνει σε μελλοντικά δεδομένα (**testing data**).
- Πως μπορούμε να καταλάβουμε εάν ο αλγόριθμός μας υπερμοντελοποιεί; Δεν έχουμε (ακόμα) τα μελλοντικά δεδομένα!

# Υπερμοντελοποίηση - Overfitting

- Δεν έχουμε μελλοντικά δεδομένα, αλλά μπορούμε να θυσιάσουμε ένα ποσοστό των δεδομένων μας, για να προσομοιώσουμε αυτό που θέλουμε:

$$\text{Data} = (x_1, y_1), \dots, (x_n, y_n)$$

$$\text{Split: } (x_1, y_1), \dots, (x_n, y_n) = (x_1, y_1), \dots, (x_m, y_m) \cup (x_{m+1}, y_{m+1}), \dots, (x_n, y_n)$$



Όλα τα δεδομένα



Δεδομένα για εκπαίδευση  
(training data)



Δεδομένα για εκτίμηση ακρίβειας  
(testing data)



# Υπερμοντελοποίηση - Overfitting

- Δεν έχουμε μελλοντικά δεδομένα, αλλά μπορούμε να θυσιάσουμε ένα ποσοστό των δεδομένων μας, για να προσομοιώσουμε αυτό που θέλουμε:

$$\text{Data} = (x_1, y_1), \dots, (x_n, y_n)$$

$$\text{Split: } (x_1, y_1), \dots, (x_n, y_n) = (x_1, y_1), \dots, (x_m, y_m) \cup (x_{m+1}, y_{m+1}), \dots, (x_n, y_n)$$



Όλα τα δεδομένα



Δεδομένα για εκπαίδευση  
(training data)




Δεδομένα για εκτίμηση ακρίβειας  
(testing data)

$$(X, y) = (X_{train}, y_{train}) \cup (X_{test}, y_{test})$$

# Υπερμοντελοποίηση – Παράδειγμα


---



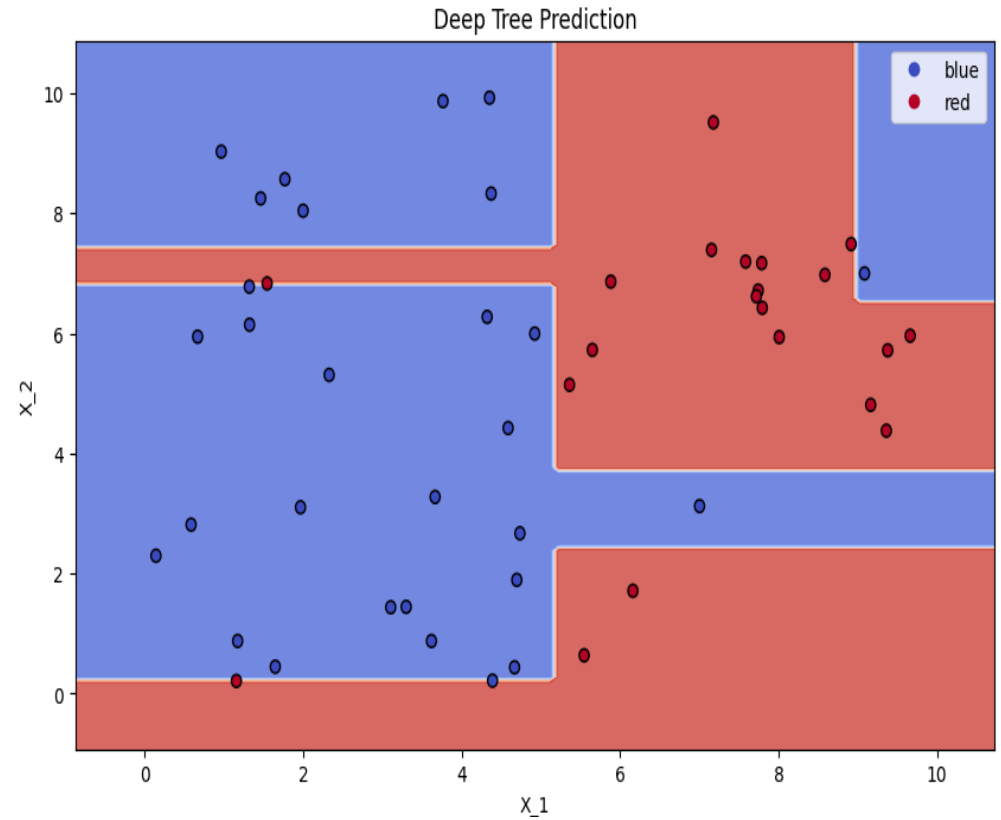
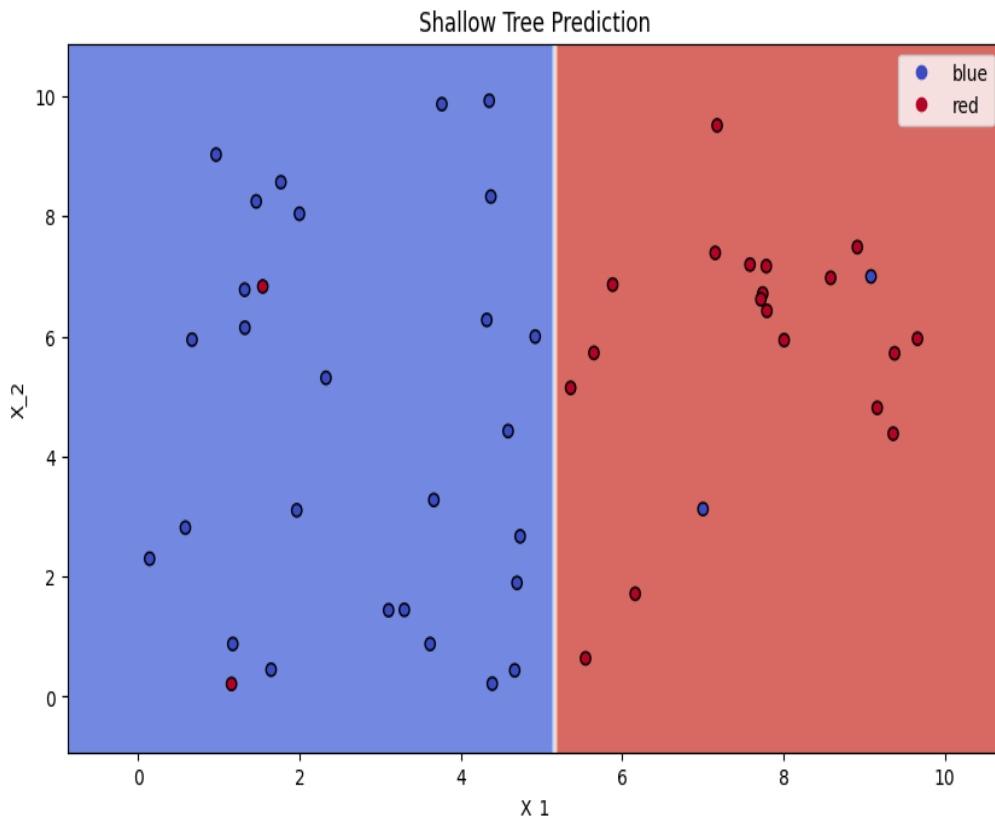
Όλα τα δεδομένα

# Υπερμοντελοποίηση – Παράδειγμα


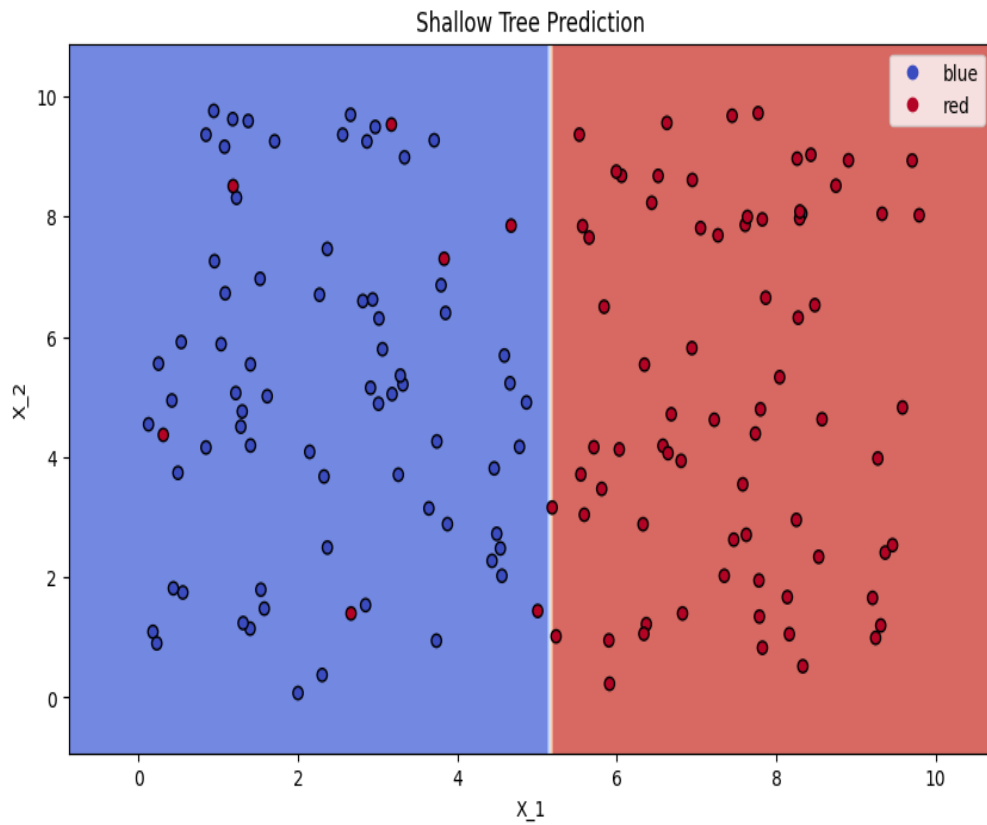
Χωρίζουμε σε δεδομένα εκπαίδευσης και δεδομένα εκτίμησης: training data + testing data



# Βαθύ και ρηχό δέντρο: δεδομένα εκπαίδευσης



# Βαθύ και ρηχό δέντρο: δεδομένα εκτίμησης



## Υπερμοντελοποίηση

---

Ενας αλγόριθμος *υπερμοντελοποιεί* εάν πετυχαίνει πολύ καλύτερη ακρίβεια στα δεδομένα εκπαίδευσης (**training data**), συγκριτικά με την ακρίβεια που πετυχαίνει στα δεδομένα εκτίμησης (**testing data**).

---

Πάντα χωρίζουμε τα δεδομένα μας σε δεδομένα εκπαίδευσης και δεδομένα εκτίμησης: η ακρίβεια του αλγορίθμου δεν είναι η ακρίβεια στα δεδομένα εκπαίδευσης, αλλά η ακρίβεια στα δεδομένα εκτίμησης

---

Ενας αλγόριθμος *υπερμοντελοποιεί* εάν πετυχαίνει πολύ καλύτερη ακρίβεια στα

Εάν υπερμοντελοποιούμε, πρέπει να περιορίσουμε την πολυπλοκότητα του αλγόριθμου: π.χ., δέντρο με μικρότερο βάθος. Υπάρχουν και άλλοι τρόποι να περιοριστεί η πολυπλοκότητα, που θα συναντήσουμε στην πορεία.

**Υπερμοντελοποίηση**

Ο βασικός σκοπός αυτής της διάλεξης είναι να καταλάβουμε τι θα πεί **υπερμοντελοποίηση**, και πως καταλαβαίνουμε εάν ο αλγόριθμος μας υπερμοντελοποιεί.