# 2. OSNOVE LINEARNOGA PROGRAMIRANJA

## 2.2. LINEARNO PROGRAMIRANJE U SLUČAJU $n = 2$

# 2.2.1. STANDARDNI OBLIK PROBLEMA LINEARNOGA PROGRAMIRANJA ZA $n = 2$

- U prethodnoj točki naveden je opći standardni oblik problema linearnoga programiranja za bilo koji $n \in \mathbf{N}$.
- Posebno, za $n = 2$ dobivamo:

$$
\begin{aligned}
&\max z = z(x_1, x_2) = c_1 \cdot x_1 + c_2 \cdot x_2 \\
&\text{p.u.} \\
&a_{11} \cdot x_1 + a_{12} \cdot x_2 \le b_1, \\
&\vdots \\
&a_{m1} \cdot x_1 + a_{m2} \cdot x_2 \le b_m, \\
&x_1 \ge 0,\ x_2 \ge 0
\end{aligned}
$$

# 2.2.2. GRAFIČKA INTERPRETACIJA PROBLEMA LINEARNOGA PROGRAMIRANJA ZA $n = 2$

- Ako bismo npr. varijablu $x_2$ shvatili kao funkciju varijable $x_1$, onda bi grafički prikaz *svakoga* pojedinoga uvjeta bio ili pravac u ravnini (ako uvjet sadrži znak =) ili poluravnina (ako uvjet sadrži znak ≤).
- U takvim slučajevima kao skup svih mogućih rješenja nerijetko se dobije *konveksan mnogokut* (geometrijski lik sa svojstvom da spojnica bilo koje dvije njegove različite točke leži unutar mnogokuta).

# 2.2.3. SLUČAJ KAD JE SKUP MOGUĆIH RJEŠENJA KONVEKSAN MNOGOKUT

- Dobijemo li kao skup mogućih rješenja konveksan mnogokut, tada je *optimalno* rješenje razmatranoga problema ili jedan vrh toga mnogokuta ili jedna stranica toga mnogokuta.
- Stoga u takvim slučajevima treba izračunati koordinate vrhova mnogokuta (rješavanjem sustava linearnih jednadžbi), a potom uvršavanjem koordinata dobivenih vrhova u funkciju cilja odrediti optimalno rješenje.